

Sveučilište u Zagrebu  
Prirodoslovno-matematički fakultet  
Biološki odsjek

Matea Vukelić  
Modeliranje koridora kretanja vukova (*Canis lupus* Linnaeus, 1758)  
u Hrvatskoj  
Diplomski rad

Zagreb, 2017.

Ovaj rad, izrađen na Zoologijskom zavodu Biološkog odsjeka Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, pod vodstvom izv. prof. dr. sc. Perice Mustafića i izv. prof. dr. sc. Josipa Kusaka, predan je na ocjenu Biološkom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu radi stjecanja zvanja magistra znanosti o okolišu.

## **ZAHVALE**

*Zahvaljujem se mentoru izv. prof dr. sc. Perici Mustafiću na brojnim stručnim savjetima, strpljenju i potpori tijekom izrade ovog rada.*

*Također se zahvaljujem komentoru izv. prof. dr. sc. Josipu Kusaku na stručnom vođenju kroz proces izrade rada, te pomoći na ključnim dijelovima diplomskog rada.*

*Posebno se zahvaljujem dr. sc. Ivanu Šulcu na nesebično uloženom vremenu i bezrezervnoj pomoći na području geografsko informacijskog sustava. Moje zahvale također idu i izv. prof. dr. sc. Svenu Jelaski na smjernicama i pomoći u prvim koracima izrade diplomskog rada.*

*Konačno, zahvaljujem se svojoj obitelji, prijateljima i dečku na strpljenju i moralnoj podršci u periodu izrade diplomskog rada i općenito na potpori tijekom studiranja.*

Sveučilište u Zagrebu

Prirodoslovno-matematički fakultet

Biološki odsjek

Diplomski rad

## **Modeliranje koridora kretanja vukova (*Canis lupus* Linnaeus, 1758) u Hrvatskoj**

Matea Vukelić

Rooseveltova trg 6, 10000 Zagreb

Prometnice u današnjem svijetu najviše utječu na fragmentaciju staništa, uznemiravanje i neposrednu smrt velikih zvijeri te tako predstavljaju jednu od najvećih prijetnji za njihov opstanak. Želimo li smanjiti negativan utjecaj prometnica, konstrukcije prikladnih struktura za prijelaz na ekološki značajnim mjestima izrazito su potrebne. Značajni dijelovi koridora za kretanje mogu biti zeleni mostovi, prolazi iznad tunela ili vijadukti. Prijelazi preko prometnica moraju biti dovoljno široki, prostrani i u prirodnom okruženju kako bi vuk bio u mogućnosti ih koristiti. Model pogodnosti staništa vuka napravila sam u Maxent programu koristeći lokacije vukova i to, telemetrijske položaje (GPS lokacije i lokacije dobivene triangulacijom), te mjesta opažanja vukova kao što lokacije nađenih mrtvih životinja, glasanja, otisaka šapa, u kombinaciji sa podacima o staništu (GIS slojevi). Podaci o staništu su : nagib terena, broj vrsta parno-prstaša, udaljenost od naselja i ruba šume, udio pašnjaka, gustoća stanovnika, Shannonov indeks, udio poljoprivrednih površina, nadmorska visina, gustoća ceste, indeks razvedenosti terena, udio šume i udaljenost od ceste. Dobiveni model pokazao je staništa pogodna za prisutnost vuka. Na kvalitetu staništa, najviše su utjecale komponente staništa: nadmorska visina, broj vrsta parno-prstaša te udaljenost od naselja. Koristeći model u GIS-u napravila sam potencijalne koridore kretanja s obzirom na moguću rasprostranjenost vuka, postojeće autoceste i objekte na njima koji su pogodni za korištenje od strane vuka. Model i kartografski prikaz mogu koristiti za procjenu utjecaja budućih prometnih infrastruktura na koridore kretanja vuka, a time i pridonositi samoj zaštiti vuka.

(62 stranice, 26 slika, 8 tablica, 59 literaturnih navoda, jezik izvornika: hrvatski)

Rad je pohranjen u Središnjoj biološkoj knjižnici.

**Ključne riječi:** Maxent, rasprostranjenost vuka, fragmentacija staništa, prijelazi za velike zvijeri

Voditelj 1: izv. prof. dr. sc. Perica Mustafić

Voditelj 2: izv. prof. dr. sc. Josip Kusak

Ocjenitelji: Dr. sc. Ana Galov, doc

Dr. sc. Neven Bočić, doc

Dr. sc. Jasenka Sremac, izv. prof

Rad prihvaćen: 05.01.2017.

BASIC DOCUMENTATION CARD
--------------------------

University of Zagreb

Faculty of Science

Department of Biology

Master Thesis

**Modelling of wolf (*Canis lupus* Linnaeus, 1758) movement corridors in Croatia**

Matea Vukelić

Rooseveltova trg 6, 10000 Zagreb, Croatia

Modern day roads have the biggest impact on habitat fragmentation and disturbance, but also on the immediate death of large carnivores which makes them one of the biggest threats for their survival. If we want to reduce the negative impact of roads, suitable crossings on ecologically relevant places are more than necessary. Significant parts of movement corridors can be green crossings, passages over tunnels and viaducts. Road crossings ought to be wide enough, spacious and in natural surroundings for the wolf to be able to use them. The model of wolf habitat suitability was created in Maxent program using wolf movement locations, telemetry data (GPS locations and locations obtained by triangulation) with the locations of animals found dead, animal sound recording, paw prints, combined with GIS environmental layers. GIS layers are: field inclination, number of ungulate species, distance from settlements, forests and roads, grassland distribution, population density, agricultural area distribution, road density, forest distribution, elevation, Shannon index and indented terrain index. The model has shown suitable habitats for wolf presence. Habitat quality is affected the most by altitude, number of ungulate species and distance from settlements. Using GIS software with the habitat suitability map I created potential movement corridors considering probable wolf prevalence, existing highways and objects on the highways which are suitable for the wolf to use. The model and cartographic representation can be used to evaluate the impact of future transportation infrastructure on wolf movement corridors, as well as contribute to protecting the wolf.

(62 pages, 26 figures, 8 tables, 59 references, original in: Croatian)

Thesis deposited in the Central Biological Library

Key words: Maxent, wolf distribution, habitat fragmentation, large carnivore crossings

Supervisor 1: Assoc. Prof. dr. Perica Mustafić

Supervisor 2: Assoc. Prof. dr. Josip Kusak

Reviewers: Dr. sc. Ana Galov, Asst. Prof.

Dr. sc. Neven Bočić, Asst. Prof.

Dr. sc. Jasenka Sremac, Assoc. Prof

Thesis accepted: 05.01.2017.

## KRATICE

AUC – Područje ispod krivulje (Area Under Curve )

ROC – Krivulja osjetljivosti tj. krivulja značajke djelovanja prijamnika (Receiver Operating Characteristic curve)

GIS – Geografski informacijski sustav (Geographic Information System)

AIC – Akaike informacijski kriterij (Akaike Information Criteria)

GLM – Generaliziran linearni model (Generalized linear model)

GAM- Generalizirani aditivni model (Generalized additive model)

## SADRŽAJ

1. UVOD.....	1
1.1. Ekologija vuka.....	1
1.1.1. Klasifikacija.....	1
1.1.2. Rasprostranjenost.....	1
1.1.3. Ugroženost populacije vukova.....	3
1.2. Izgled i građa tijela.....	4
1.3. Način života.....	6
1.3.1. Razmnožavanje vukova.....	8
1.3.2. Prehrana vukova i napad na stoku.....	9
1.4. Praćenje populacije vukova.....	11
1.4.1. Telemetrijsko praćenje i foto zamke.....	11
1.5. Prometnice.....	16
1.5.1. Autoceste i velike zvijeri.....	16
1.5.2. Utjecaj prometnica na populaciju vukova.....	17
1.6. Očuvanje populacije velikih zvijeri.....	21
1.7. Cilj istraživanja.....	23
2. MATERIJALI I METODE.....	24
2.1. Modeliranje distribucije vrsta.....	24
2.1.1. Maxent.....	24
2.1.1.1. AUC područje i ROC krivulja.....	26
2.2. ENM Tools.....	27
2.2.1. AIC.....	27
2.3. GIS.....	28
2.4. Područje istraživanja.....	28
2.5. Prikupljani podaci o vukovima.....	30
2.6. Ekološke varijable.....	31
2.6.1. Korelacija između varijabli.....	33
2.7. Priprema podataka.....	33

2.8. Izrada prediktivnog modela staništa.....	34
2.9. Modeliranje koridora kretanja.....	35
3. REZULTATI.....	36
4. RASPRAVA.....	52
5. ZAKLJUČAK.....	56
6. LITERATURA.....	57
ŽIVOTOPIS.....	63



## 1. UVOD

### 1.1. Ekologija vuka

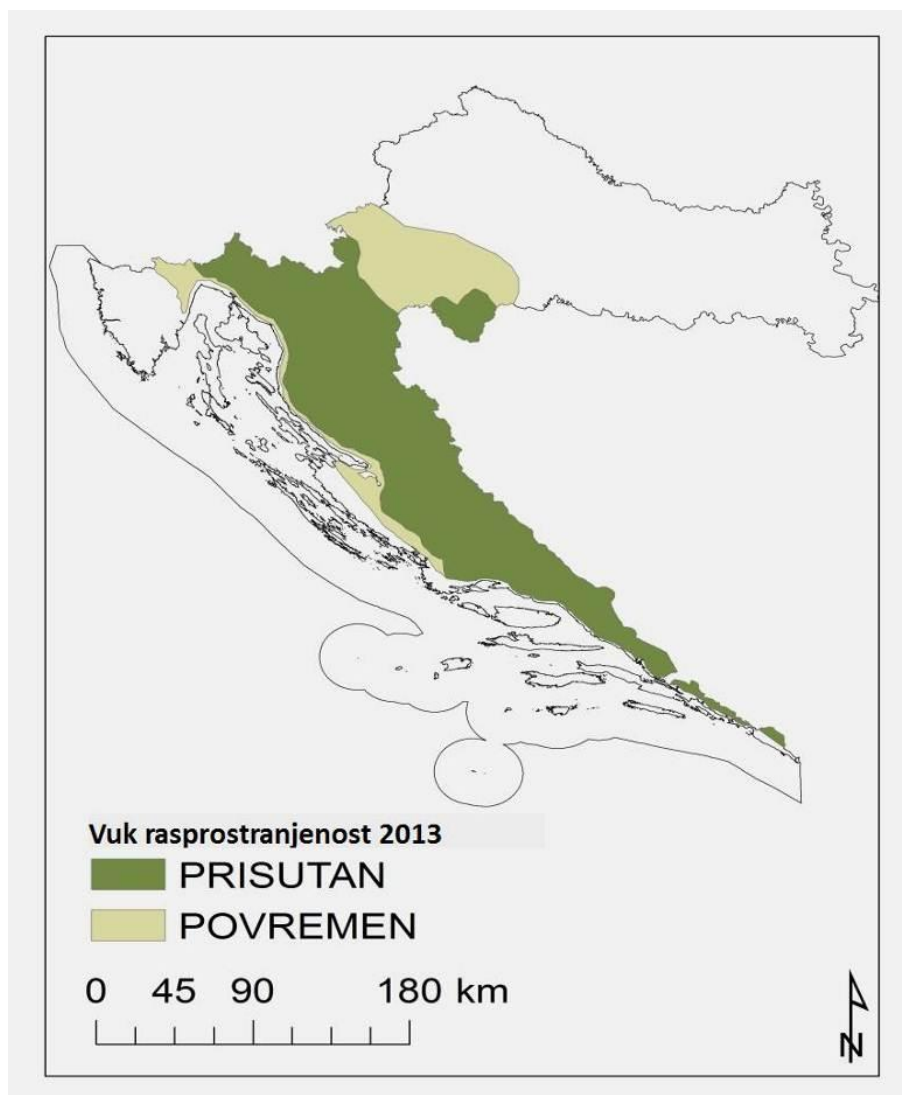
#### 1.1.1. Klasifikacija

Vuk (*Canis lupus* Linnaeus, 1758) je sisavac iz reda zvijeri (*Carnivora*), porodice pasa (*Canidae*) i roda pas (*Canis*). U svijetu su osim sivog vuka (*Canis lupus* Linnaeus, 1758) poznate još dvije vrste: crveni vuk (*Canis rufus* Linnaeus, 1758) i abesinijski vuk (*Canis simensis* Linnaeus, 1758). Procesom udomaćivanja vuka nastale su sve pasmine pasa, stoga se danas smatra da su vuk i pas ista vrsta. (Kusak, 2004).

#### 1.1.2. Rasprostranjenost

Nekada se vuk nalazio na većini staništa sjeverne polutke, uključujući Sjevernu Ameriku, Euroaziju i Japan. U prošlosti je zbog čovjekova istrebljenja nestao u svim dijelovima središnje i sjeverne Europe (Boitani, 2000). Zadnjih dva desetljeća populacija se počela oporavljati na područjima Francuske, Njemačke, Norveške, Švicarske, Švedske. Danas se u Europi mogu pronaći veće populacije u Rumunjskoj, Španjolskoj i na području Balkana. (Kaczensky i sur., 2013). Iako podatci govore da je broj vukova u Europi velik, problem je rascjepkanost tih populacija. Samo par država broji populaciju veću od 1000 jedinki (Kaczensky i sur., 2013).

Vukove danas nalazimo u planinama. Hrvatski dio Dinarida čini poveznicu između planinskih dijelova Slovenije i Bosne i Hercegovine. Žumberak čini poveznicu sa Slovenijom, a dijelovi Banije s Bosnom i Hercegovinom. Populacija vuka u Hrvatskoj je stabilna i redovito se prati kao dio upravljanja populacijom. Vuk je stalno prisutan na 31,9 posto kopnenog dijela Hrvatske, a povremeno se pojavljuje na 12,9 posto (Slika 1.). Populacija se prostire na području 9 županija: Sisačko-moslavačka, Karlovačka, Ličko-senjska, Primorsko-goranska, Istarska, Zadarska, Šibensko-kninska, Splitsko-dalmatinska i Dubrovačko-neretvanska (Jeremić i sur., 2015).



Slika 1. Stalna i povremena prisutnost vuka u 2013. (Štrbenac i sur., 2010)

Populacija vuka u Hrvatskoj dio je veće Dinarsko-balkanske populacije koja nastanjuje široko područje od Slovenije do sjeverne Grčke, koje sadrži Dinarski masiv koji se proteže kroz Hrvatsku, Bosnu i Hercegovinu, zapadnu Srbiju i Kosovo, Crnu Goru, Makedoniju, Albaniju te zapadnu i južnu Bugarsku. Populacija je pretežno kontinuirana kroz područja, iako za kvalitetnu procjenu nisu potpuni svi podatci. Otprilike 5 000 jedinki čini populaciju, premda se lokalna gustoća može uvelike razlikovati (Štrbenac i sur., 2010).

Prvim istraživanjem genske raznolikosti provedenim od 2005.-2008. pronađeno je šest različitih vučjih markera u Hrvatskoj, od kojih se tri podudaraju s onima nađenima u Alpama. Istovjetni markeri upućuju da životinje potječu od zajedničkih predaka (Gomerčić i sur., 2010).

### 1.1.3. Ugroženost populacije vukova

Vuk se može prilagoditi raznim ekološkim čimbenicima. Njegovu rasprostranjenost najviše uvjetuju dostupnost hrane, pokrivenost staništa šumom i utjecaj čovjeka. Utjecaj čovjeka najviše vidimo preko gradnje prometnica i neposrednim ubijanjem (Chapron i sur., 2014). Biološki kapacitet vuka određen je ukupnom veličinom staništa, količinom raspoloživog plijena i socijalnim odnosima u čoporu. Količina prirodnog plijena u Hrvatskoj je ispod mogućeg kapaciteta, što ograničava kapacitet staništa za vuka (Huber i sur., 2010).

U današnje vrijeme čovjek je postao glavna prijetnja populaciji vuka, bilo to izravno ili neizravno. Utjecaj ljudi na vukove možemo razvrstati u tri kategorije: 1) utjecaj na stanište (izgradnja prometnica, turizam, zagađenje), 2) utjecaj na plijen (lovno gospodarenje, ali i krivolov), 3) izravni utjecaj na populaciju vuka (izravno stradavanje na prometnicama, odstrjel, zamke, uzimanje jedinki i držanje u zatočeništvu (Slika 2.)) (Anonymous, 2016).



Slika 2. Vukovi u zatočeništvu trajno su izgubljeni za prirodu (izvor: [http://www.dzpz.hr/slike\\_upload/20100303/dzpz201003031313290.jpg](http://www.dzpz.hr/slike_upload/20100303/dzpz201003031313290.jpg))

Procjenjuje se da u Hrvatskoj živi od 126-186 jedinki raspoređenih u 49 čopora od kojih 22 čopora dijelimo sa Slovenijom i Bosnom i Hercegovinom (Jeremić i sur., 2015). Vuk je 1995. godine proglašen zaštićenom vrstom u Hrvatskoj te je svako ubijanje i uznemiravanje postalo protuzakonito (Štrbenac i sur., 2010). Tada je počelo i praćenje smrtnosti na cijelom području njihove rasprostranjenosti u Hrvatskoj. Nažalost, zaštita im nije omogućila sigurniji opstanak i zato je izrađen prvi plan upravljanja vukom 2005., te njegova revizija 2010. godine (Štrbenac i sur., 2010, Štrbenac i sur., 2005). Glavni ciljevi petogodišnjeg plana upravljanja su: jačanje svijesti o vuku, dobivanje potpore javnosti te osiguravanje dugoročnog očuvanja u Hrvatskoj (Štrbenac i sur., 2010).

## 1.2. Izgled i građa tijela

Vuk je najveći pripadnik porodice pasa te drugi predator po veličini u Europi, odmah iza medvjeda (Clutton-Brock i Greensmith, 2002). Na području Hrvatske prosječna masa mužjaka iznosi 30 kg, a ženke 24 kg (Platiša i sur., 2011). Mjereno u grebenu prosječna visina je 70 cm, a dužina mjerena od vrha nosa do vrha repa iznosi 170 cm (pri čemu dužina repa iznosi približno 40-ak cm) (Platiša i sur., 2011).

Na boju krzna utječe stanište u kojem vuk obitava, starost, spol, godišnje doba i zdravlje životinje (Boitani, 2000). Boja krzna vuka u Hrvatskoj uvijek je sive boje dok varira samo njen intenzitet (Slika 3.). Prsa, trbuh i noge su svijetlo sive boje, dok su leđa i rep tamno sivi (Kusak, 2004). U kutovima usana može se nalaziti bijela boja pa se naizgled dobiva dojam vučjeg osmijeha (Janicki i sur., 2007).



Slika 3. Odrasli vuk (izvor : <http://img.photobucket.com/albums/v603/sefica/vuk.jpg>)

Noge su čvrste i duge što ga čini prilagođenim brzom i dugotrajnom trčanju (Kusak, 2004). Hodaju na prstima, kojih je na stražnjim nogama četiri, a na prednjim pet. Peti prst na prednjim nogama ne dotiče zemlju (Boitani, 2000). Šape okrenute prema van, laktovi uvučeni prema unutra i uski grudni koš omogućavaju kretanje prednje i stražnje noge jedne strane u istoj ravnini (Kusak, 2004). Glava je duguljasta, a lubanja teška i široka.

Zubalo s 42 zuba ima mesojedne karakteristike. Najdulji su očnjaci čija je funkcija hvatanje i ubijanje plijena. Za trganje plijena na komadiće koriste zadnji pretkutnjak u gornjoj čeljusti i prvi kutnjak u donjoj čeljusti (Hanzak, 1974). Lomljenje kostiju postižu kutnjacima, dok je zadnji kutnjak u donjoj čeljusti zakržljao (Janicki i sur., 2007). Zubi mogu poslužiti i za određivanje starosti jedinke metodom brojanja prstena u zubnom cementu, tako da se na broj prstena nadodaju još dvije godine. Najpogodniji za određivanje je prvi pretkutnjak jer se može uzeti s uspavane životinje (Kusak, 2004).

Vukovi imaju odlično razvijena osjetila, posebice sluh i osjet mirisa. Zbog njihovih dobro razvijenih mentalnih sposobnosti vukovi se mogu prilagoditi na mnogo različitih staništa i okolišnih uvjeta (Hanzak, 1974).



### 1.3. Način života

Vukovi su društvene životinje i većinu života provedu u skupini koju nazivamo čopor (Clutton-Brock i Greensmith, 2002). Reproductivni par, mužjak i ženka, čine srž čopora, dok su ostali članovi potomci izvornog obiteljskog para (Slika 4.). Između članova čopora postoje snažne socijalne veze koje reguliraju dinamiku čopora te je sam čopor hijerarhijski ustrojen (Boitani, 2000). Roditeljski par ima dominantan položaj i ima privilegiju kod hranjenja i reprodukcije. Ostali članovi su podčinjeni pa se hrane nakon nadređenih (Kusak, 2004). Mjesto brloga i vrijeme kada se ide u lov također odlučuje dominantan vuk ili vučica. Samoregulacija veličine čopora očituje se u činjenici da se samo jedna dominantna ženka smije pariti i imati mlade, dok se ostalim podčinjenim članovima onemogućava parenje. Time se sprječava parenje u srodstvu (Kusak, 2004).



Slika 4. Vukovi u čoporu (izvor: <http://otvoreno.ba/wp-content/uploads/2015/12/vukovi.jpg>)

Hijerarhija u čoporu može se mijenjati ovisno o snazi članova čopora, a najveći utjecaj na promjene ima vrijeme prije i tijekom parenja. Mladi ostaju u čoporu do druge godine života, a nakon toga slijedi razdoblje kada biraju žele li ostati i dalje u čoporu ili ga napustiti (Boitani, 2000). Razlozi napuštanja mogu biti nedostatak hrane za podčinjene članove, nemogućnost razmnožavanja, velika gustoća vukova, dostupnost plijena i slobodnog teritorija (Kusak, 2004). Mladi odlaze u disperziju u potrazi za novim staništem i partnerom. Ukoliko uspije pronaći teritorij na kojemu nema drugih vukova osim mladog vuka suprotnog spola s kojim nije u srodstvu, uz uvjet da ima dovoljno plijena, oni mogu

oformiti novi čopor. Novi par počinje obilježavati svoj teritorij urinom, izmetom, grebanjem po tlu i zavijanjem. Nakon što se međusobno socijaliziraju, zimi se pare, a u proljeće odgajaju prvo leglo (Kusak, 2004).

Vukovi u čoporu zajedno putuju, odmaraju, love i hrane se. Lov u skupini omogućava im uhvatiti veći plijen kojeg mogu odmah u potpunosti pojesti. Čopor prosječno ima sedam članova (2-15), s time da veličina čopora ne mora biti ista veličini grupe za lov (Kusak, 2004). Zimi pretežno cijela obitelj sudjeluje u lovu, dok ljeti love u pojedinim hranidbenim grupama jer tada jazbina zahtijeva zaštitu ostalih članova čopora (Boitani, 2000).

Plijen snažnim ugrizom hvataju za vrat, trzanjem kidaju tkivo i vratne krvne žile od čega plijen ubrzo iskrvari do smrti. Veći plijen, na primjer govedo, ne hvataju za vrat već za stražnje noge ili but. Naposljetku iskoriste cijeli plijen od kojeg preostane samo kralježnica i koža (Kusak, 2004).

Ukoliko strani vuk dođe na teritorij čopora i otkriju ga, najčešće biva ubijen i pojeden. Na taj način braneći teritorij osiguravaju si i hranu (Kusak, 2004). Veličina teritorija čopora ovisi o količini plijena, gustoći vukova, značajkama staništa na kojem obitavaju, utjecaju ljudskog uznemiravanja i infrastrukture koju je izgradio čovjek (Boitani, 2000). Teritorij se aktivno obilježava urinom, fecesom i zavijanjem. Svoju prisutnost ili uhvaćeni plijen najavljuju zavijanjem. Na taj način pokazuju da je teritorij zauzet te tako izbjegavaju konfrontaciju, pošto obilježavanje mirisom nema učinak na veće udaljenosti (Kusak, 2004). Zavijanjem pozivaju na okupljanje članova čopora, posebno ljeti na okupljalištu čopora gdje mladi uče kroz igru kako zavijati (Kusak, 2004). U šumskom staništu zavijanje mogu čuti i do 11 km (Mech i Boitani, 2003).

Socijalno ponašanje, teritorijalnost i disperzija unutrašnji su mehanizmi regulacije gustoće vukova. Socijalno ponašanje, broj reproduktivnih ženki i teritorijalnost ograničavaju broj čopora, a disperzija pridonosi širenju populacije i povećanju izmjene gena (Boitani, 2000).

### 1.3.1. Razmnožavanje vukova

Sezona parenja za vukove traje od kraja siječnja do travnja. Vučica se tjera jednom godišnje u trajanju od tri tjedna te se parenje događa u trećem tjednu. Skotnost u vukova traje 63 dana, nakon čega se ženka koti u brlogu (Kusak, 2004). Osjeća li se majka ugroženo iz bilo kojeg razloga premjestit će brlog na sigurnije mjesto. U slučaju da se brlog ne uznemiri, vukovi će ga koristiti i više godina zaredom. Čopor obično ima jedno leglo dominantnog para, a za mlade se brinu svi članovi čopora koji su pretežno rodbinski povezani. Vučica okoti najčešće 4-7 mladih koji su slijepi i gluhi od 11 do 15 dana nakon poroda. Mladi sišu do dobi od šest do osam mjeseci, a nakon toga prelaze na hranu koju donose svi članovi čopora (Slika 5). Dok ne dosegnu veličinu odraslog vuka i ne počnu putovati za čoporom, mladi se nalaze na mjestu koje nazivamo okupljalište. Mladi tijekom odrastanja borave na okupljalištu, a odrasli članovi čopora tamo se vraćaju svaki dan. Spolno zreli su s dvije godine života, nakon čega odlučuju hoće li napustiti roditeljski čopor i pokušati osnovati svoj ili ostati u izvornom čoporu (Kusak, 2004).



Slika 5. Vučje leglo (izvor: Vedran Slijepčević)

Genetičke analize intra i inter-čoporskih odnosa pokazale su značajno miješanje gena između susjednih čopora (Boitani, 2000).



### 1.3.2. Prehrana vukova i napadi na stoku

Prehrana vukova ovisit će o količini plijena i njegovoj dostupnosti s obzirom na sezonske varijacije i staništu u kojemu se trenutno nalazi. Njegov plijen mogu biti veliki sisavci, mali kralješnjaci, beskralješnjaci, biljke i strvine (Boitani, 2000). Glavni izvor hrane su parno-prstaši (jelen, srna, divlja svinja) i manji sisavci (zec, glodavci). Glavne vrste parno-prstaša u šumama nizinskih dijelova Hrvatske su srna i divlja svinja, dok se u većim šumama nalazi i jelen. Planinske dijelove nastanjuju srne, divlje svinje i jeleni, a na južnom dijelu Velebita mogu se pronaći i populacije divokoza i muflona. Mediteransko područje ima samo populacije divljih svinja, a Biokovo nastanjuju i divokoze. Brojnost parno-prstaša utječe na gustoću vukova (Štrbenac i sur., 2010).

U potrazi za plijenom, pogotovo u područjima gdje ga je manje, vukovi napadaju domaće životinje. Najviše stradavaju koze i ovce, ali osim njih često napadaju i konje, magarce, goveda i pse (Štrbenac i sur., 2008). Domaće životinje čine većinu hrane na području Dalmatinske zagore, dok su parno-prstaši najveći plijen u Gorskom kotaru. Najveće štete na domaćim životinjama su na području Dalmacije (Šibensko-kninske i Splitsko-dalmatinske županije) gdje se zbog nedostatka plijena vuk okreće upravo njima.

Analizom podataka za 2008. godinu pokazalo se da je od vuka ukupno stradalo 0,51 posto ovaca i 0,94 posto koza od ukupnog broja koza i ovaca na tim područjima. Analiza je rađena na područjima gdje je vuk stalno ili povremeno prisutan (Štrbenac i sur., 2010).

Poduzete mjere za zaštitu stoke od napada vuka su: uvođenje električnih ograda (Slika 6.) i korištenje pastirskih pasa. Jedno od najboljih rješenja za problem štete na stoci koju uzrokuje vuk je kontrolirani nadzor stoke. Pokazalo se da je šteta puno manja ili je čak nema na pojedinim mjestima gdje se stoka nadzire (Anonymous, 2016).



Slika 6. Donirana električna ograda ( izvor:<http://www.life-vuk.hr/mjere-zastite-stoke/elektricne-ograde/sto-je-elektricna-ograde-198.html>)

U slučaju da dođe do štete na domaćim životinjama stočarima se, osim novčanih naknada, doniraju električne ograde i pastirski psi kojima se pokušava ublažiti gubitak (Štrbenac i sur., 2008). Električni impulsi koji prolaze kroz ogradu uzrokuju šok životinji koja ju dotakne, bez prijetnje za život. Prvo se donira stočare na području Like, Gorskog kotara i Dalmacije jer obitavaju na područjima kretanja vučjih čopora. Na temelju dosadašnjih rezultata utvrđeno je da je uvođenje pasa tornjaka (Slika 7.) kao čuvara životinja dovelo do olakšanja u čuvanju stoke i smanjenja štete (Štrbenac i sur., 2010).



Slika 7. Tornjak čuva stado ovaca (Štrbenac i sur., 2008)

#### 1.4. Praćenje populacije vukova

Godišnja izvješća o populaciji vuka izrađuje Državni zavod za zaštitu prirode u suradnji sa znanstvenicima s Veterinarskog fakulteta u Zagrebu. Za procjenu veličine populacije koriste se metode prikupljanja podataka preko znakova prisutnosti kao što su tragovi (u snijegu, blatu, pijesku), izmet, ostatci plijena, podaci o šteti na stoci, genetička istraživanja, telemetrijska istraživanja i praćenje foto-zamkama. Na karte se ucrtavaju viđene lokacije vučjih čopora i broj jedinki koji se pretpostavlja za svaki čopor. Populacija vuka na pojedinom području tumači se brojem čopora sukladno lokacijama zajedno s telemetrijski određenim veličinama teritorija čopora te prosječnim dnevnim kretanjima vukova u tom staništu (Anonymous, 2016).

Populaciju velikih zvijeri, odnosno utjecaj prometa na populaciju, počeo je pratiti Alojzije Frković. Smrtnost vuka počeo je bilježiti 1945. godine. Prvim praćenjem pokazalo se da promet uvelike utječe na veličinu populacije, što vidimo iz podataka da je od 1945. do 1996. godine 20 jedinki koje su bile starosti manje od godinu dana izravno ubijeno zbog prometa (Kusak i sur., 2000). Najveća smrtnost vukova bila je 1960-ih godina jer su tada još bile organizirane hajke i trovanja vukova. Tijekom 2007. godine zabilježena je smrtnost 17 vukova. Glavni uzrok je promet od kojeg je stradalo devet vukova. Pet je odstrijeljeno (1 ilegalno), jedan je uginuo od bjesnoće, a uzrok smrti ostala dva vuka je nepoznat (Štrbenac i sur., 2008). Brojke mogu biti vrlo pristrane jer se za smrtnost od prometa uvijek sazna, dok nezakonito ubijanje i prirodni uzroci (bolesti, drugi vukovi) ostaju nezabilježeni.

##### 1.4.1. Telemetrijsko praćenje i foto zamke

Telemetrijsko praćenje zasniva se na hvatanju jedinke, obilježavanju ogrlicom s radio odašiljačem i puštanju nazad u prirodu (Anonymous, 2016). Vukovi su obilježeni GPS ogrlicama koje su omogućile njihovo praćenje putem satelita te su dobiveni podatci o njihovoj lokaciji i aktivnosti (Slika 8.). Praćenje u trajanju od najmanje jedne godine može odrediti gdje je teritorij čopora kojem pripada obilježeni vuk. Može se odrediti potomstvo čopora, mjesto brloga, mjesto noćnih aktivnosti, napuštanje čopora i smrtnost. Tragovima u snijegu, slušanjem zavijanja ili izravnim promatranjem može se odrediti broj vukova u čoporu (Kusak, 2010).



Slika 8. Obrada uspavane vučice i stavljenje GPS ogrlice je početak telemetrijskog praćenja (izvor: Bejan Lortkipanidzel)

GPS ogrlice omogućuju učestalo dobivanje informacija o kretanju zvijeri (neovisno o vremenu i udaljenosti) i veću preciznost od VHF ogrlica (Arthur i Schwartz, 1999). VHF ogrlice zahtijevaju više uloženog vremena i troškova za određivanje lokacije životinje, a pogodne su zbog njihove male mase koja omogućava obilježavanje mladih životinja, odnosno životinja manje mase (Slijepčević, 2009). Telemetrijska istraživanja u Hrvatskoj provode Veterinarski fakultet Sveučilišta u Zagrebu i OIKON Institut za primijenjenu ekologiju (Jeremić i sur., 2015).

Neki od telemetrijski praćenih vukova

Max (Slika 9.) je uhvaćen 12. rujna 2007. godine na Pogorelom vrhu u lovištu hrvatskih šuma „Smrekova draga - Gumance“. Izvorni čopor naziva Suho ponekad napušta i istražuje susjedna područja. Njegovo kretanje pokrilo je područje četiri praćena čopora te je tijekom 443 dana praćenja prešao 1.153,8 km<sup>2</sup>, što je najviše za vuka u Hrvatskoj. Pronađen je mrtav 2008. godine (Štrbenac i sur., 2010).



Slika 9. Vuk Max (izvor: Josip Kusak)

Vučica Rina (Slika 10.) uhvaćena je 29. listopada 2007. godine nedaleko od Crnog Luga ispod vrha Šije, pripada čoporu Risnjak. Postala je prva vučica iz tog čopora praćena GPS odašiljačem (Štrbenac i sur., 2008).



Slika 10. Vučica Rina (izvor: Vedran Slijepčević)

Ženka Tara (Slika 11.) nedaleko od mjesta Stolac (Velebit) obilježena je 16. kolovoza 2007. godine, uhvaćena je na području nekadašnjeg čopora Jelovec. Tarina ogrlica davala je informacije o kretanju i aktivnosti u tada neistraženom dijelu Hrvatske. Prestala je raditi 2009. godine (Štrbenac i sur., 2008).





Slika 11. Vučica Tara (Izvor: Vedran Slijepčević)

Praćeni čopori u Hrvatskoj su:

#### Risnjak

Prati se od ljeta 2002. godine, s prvom obilježenom vučicom Hildom, kada je čopor bilježio 6 vukova. Područja kretanja čopora su između Crnog Luga, Delnica i Lokvi, ali i s druge strane Risnjaka, do livade Lazac, Vilja, Gornjeg Jelenja i Suhe Rečine. Zadnji podatci su iz 2013. godine kada je pronađena ogrlica vučice Tone na području Crnog Luga. (Anonymous, 2016, Kusak, 2010).

#### Snježnik

Prati se od 2002. godine putem pet telemetrijski praćenih vukova. Vučica Hilda, koja je najdulje praćeni vuk u Hrvatskoj, napušta čopor Risnjak te postaje reproduktivna ženka čopora Snježnik. Na osnovi lokacije tri praćena vuka 2010. godine veličina teritorija procijenjena je na 759,8 km<sup>2</sup>. Od 2012. do 2014. godine čini se da čopor ne postoji, ali se kasnije opet oformio (Jeremić i sur., 2015).

#### Suho

Čopor Suho prati se od 2006. godine kada su obilježeni vukovi Noah i Grga. Praćenjem čopora dobilo se puno više informacija o kretanjima i broju vukova na sjevernom dijelu Gorskog kotara. Teritorij čopora procijenjen je na 372 km<sup>2</sup> tijekom 2006./2007. godine. Tijekom 2012. godine na području čopora zabilježeno je puno manje znakova prisutnosti nego prije (Kusak, 2010).

## Krasno (Jelovac)

Čopor Jelovac prati se od 2003. godine kada je obilježena vučica Jelica na području iznad Krasna. Kasnije je čopor preimenovan na prijedlog mještana koji su bili uključeni u praćenje vukova. Teritorij čopora dvostruko je veći od onih u Gorskom kotaru te je putem lokacija vučice Tare dobiven podatak od 629,6 km<sup>2</sup>. Od 2013. godine čopor je značajno pao u svojoj brojnosti (Kusak, 2010).

## Foto-zamke

Osim telemetrijskog načina praćenja postoji i praćenje foto-zamkama. Njihovim korištenjem, a kasnije i interpretacijom rezultata mogu se unaprijed predvidjeti potrebni objekti za prijelaz životinja preko cesta. Foto-zamkama također se može bilježiti i prolaznost životinja preko izgrađenih objekata. Postavljaju se na područja na kojima je poznato da životinje obitavaju ili redovito prolaze (Slika 12.). Aktiviraju se senzorom koji bilježi svaku prisutnost životinje. Daje nam podatke o prisutnosti i mogućem broju velikih zvijeri, podatke o korištenju prostora, dnevnoj i sezonskoj učestalosti prolaza i aktivnosti ostalih sisavaca (Gužvica i sur., 2005.)



Slika 12. Životinje fotografirane foto zamkama: **a** vuk, **b** smeđi medvjed (Kusak i sur., 2009)


## 1.5. Prometnice

### 1.5.1. Autoceste i velike zvijeri

Ograđene autoceste predstavljaju relativno nepropusnu barijeru za populaciju vuka. Zvijeri prelaze ogradu autocesta zbog otpada koji se odlaže uz autocestu u neodgovarajućim kantama za smeće, lešina životinja na prometnici, ali i potreba prijelaza radi ostalih životnih potreba (pored hranjenja). Upravo zato su prijelazi preko autocesta od kritične važnosti (Huber i Kusak, 2000).

U Hrvatskoj 400 km autocesta koje su u prometu ili gradnji prolazi staništem vukova (Kusak i sur., 2009). Autocesta Zagreb-Rijeka pruža se kroz 68,5 km područja velikih zvijeri te prolazi kroz njihovo glavno stanište u Gorskom kotaru (Kusak i sur., 2009). Ima veliki broj tunela, vijadukata i mogućih koridora prijelaza (Huber i Kusak, 2000). Kritični dijelovi autoceste su posebna mjesta gdje su naleti vozila na životinje češći nego na ostalim dijelovima ceste (Huber i Kusak, 2000).

Najvažniji koridor za sve tri vrste nalazi se u centralnom dijelu Gorskog kotara (Kusak i sur., 2000). U blizini Delnica 1999. godine sagrađen je Dedin, prvi zeleni most za prelaženje životinja (Slika 13.).



Slika 13. Zeleni most Dedin (izvor: <https://www.arz.hr/hr/autocesta/dionice/delnice-ravna-gora>)



Kusak i sur. (2009) izračunali su frekvenciju prijelaza preko mosta Dedin. Koristili su kombinaciju zapisa infracrvenim senzorima i brojevima tragova na 1,5 m širokoj pješčanoj traci postavljenoj kroz cijelu širinu mosta. Kroz razdoblje od 793 dana praćenja dobiveni su rezultati od minimalno 125 prijelaza vuka preko mosta Dedin od ukupnih 12519 prijelaza svih divljih životinja (Kusak i sur., 2009). Prosječno 17 velikih životinja prijeđe dnevno preko mosta (Huber, 2001). Most Dedin veliku frekvenciju prijelaza duguje svojoj lokaciji, koja je poznata po velikim aktivnostima i prijelazima divljih životinja. Životinja ima jasan pregled iz šume na most preko autoceste i na rub šume sa druge strane. Most je udaljen od naselja i nalazi se u prirodnom okruženju šume (Kusak i sur., 2009).

Autocesta od Bosiljeva do Splita s najmanje 200 km duljine zadire u teritorij barem 15 vučjih čopora. Izgradnjom ove autoceste ona ima utjecaj na 50 % populacije vuka, ako računamo da je prosječan broj vukova u čoporu šest (Huber i Kusak, 2000). Iako postoje prijelazi i žičane ograde duž autoceste, automobili i dalje nalijeću na životinje. Tako su 2012. godine naleti na životinje zauzimali 20 % od ukupnog broja prometnih nezgoda (Vivoda i sur., 2014).

#### 1.5.2. Utjecaj prometnica na populaciju vukova

Moderni svijet zahtijeva sve više konstrukcija i prometnica u dosad netaknutim dijelovima prirode. Prometne infrastrukture uzrokuju modifikacije u ponašanju životinja te tako utječu na ekosustave (Kusak i sur., 2009). Jedna od najvećih prijetnji za opstanak vuka je fragmentacija njegovih staništa, koja je prepoznata kao jedan od najvažnijih uzroka smanjenja biološke raznolikosti (Štrbenac i sur., 2008). Prisiljava ih na približavanje čovjeku i njegovim objektima te ih ograničava u njihovim životnim potrebama. U određenim trenucima zbog antropogenog utjecaja život pojedinoj vrsti može biti i onemogućen (Huber i Kusak, 2000). Velike zvijeri posebno su osjetljive na fragmentaciju zbog njihovog malog broja, potrebe za velikim prostorom kako bi zadovoljile sve životne potrebe i zbog izravnog progona ljudi (Kusak i sur., 2009). Čopor vukova ima svoj teritorij koji će braniti od ostalih vučjih čopora. Na tom teritoriju mora imati dovoljno prostora kako bi uhvatio dovoljno plijena za sebe, ali i mladunčad te imati potrebni mir oko brloga. Na području Dalmacije veličina teritorija jednog čopora iznosi 150 km<sup>2</sup>, u Gorskom kotaru 350 km<sup>2</sup> dok na Velebitu i do 700 km<sup>2</sup>. Ukoliko čopor bude izoliran od drugog čopora, može doći do prekida protoka gena te do smanjenja raznolikosti, što populaciju može činiti osjetljivom na promjene u okolišu (Kusak, 2010).

Ukoliko im se smanji teritorij zbog unošenja zapreka (npr. prometnica), cijeli čopor može propasti. Također se mogu očekivati i sve veće štete na domaćim životinjama jer smanjivanjem površine staništa smanjuje se i populacija plijena parno-prstaša (Huber i Kusak, 2000).

Prometne infrastrukture povećavaju rubni efekt, razbijaju kontinuiranost staništa, ugrožavaju sposobnost preživljavanja kao rezultat genske izoliranosti (Huber i sur., 2002). Osim navedenih, prometnice imaju i druge loše utjecaje na staništa. Buka, svjetlosno onečišćenje te emisije plinova u atmosferu i vodu (Vivoda i sur., 2014).

U Hrvatskoj autoceste sijeku staništa divljih životinja uzduž i poprijeko. Telemetrijskim praćenjem divljih zvijeri na području Gorskog kotara utvrđeno je da sve tri vrste prelaze autocestu te čak imaju životne prostore s obje strane ceste (Kusak i sur., 2009). Postojeće autoceste moraju pružiti minimalne uvjete kretanja zvijerima jer osim nemogućnosti njihovog opstanka, uzrokuju velike štete na vozilima prilikom sudara i time predstavljaju opasnost za putnike (Huber i Kusak, 2000).

Postavljanje žičanih ograda duž autocesta i osiguravanje prijelaza životinjama radi sprječavanja fragmentacije njihovih staništa korisno je za same životinje, ali i za sigurnost prometa (Vivoda i sur., 2014). Uzeći u obzir da ograde smanjuju vjerojatnost sudara treba napomenuti da također fragmentiraju staništa.

Pravilnik o prijelazima za divlje životinje donesen je 2007. godine. Njime se propisuju mjere zaštite i način održavanja prijelaza preko prometnica ili građevina koje sijeku migracijske putove životinja (Štrbenac i sur., 2010).

Prijelazi:

I. kategorije su postojeći prijelazi za divlje životinje širine do 600 m i posebno izgrađeni prijelazi kao zeleni mostovi, vijadukti i tuneli koji su zaštićeni kao prirodne vrijednosti (Štrbenac i sur., 2010).

II. kategorije su postojeći objekti širi od 600 metara koji se koriste kao prijelazi za sve divlje životinje te su u njima zabranjene sve aktivnosti s trajnim učinkom na funkcionalnost prijelaza (Štrbenac i sur., 2010).

Koridori označavaju područja koja spajaju veće komplekse staništa pojedine vrste. Od iznimne je važnosti da su koridori dovoljno široki, prostrani i u prirodnom okruženju jer u protivnom životinje oprezne kao vuk, neće koristiti. Životinja tada može pokušati prijeći cestu sama ili ostati s jedne strane zapreke. Ostane li izolirana na jednoj strani smanjuje joj se mogućnost za pronalaženje hrane, vode, zaklona za odmor, izbjegavanje čovjeka, izbjegavanje konkurenata i pogibelji od predstavnika svoje vrste (Huber, 2001). Prijelazi preko autocesta bitni su sastavni dijelovi koridora. Prijelazi bi se trebali nalaziti svakih nekoliko kilometara ako prometnice prelaze preko staništa vuka. Tijekom njihove gradnje treba sačuvati što više autohtone vegetacije (Huber, 2001).

Objekti u području autocesta koji mogu poslužiti kao prijelazi za divlje životinje (Huber i sur., 2002):

1) Prolazi

Grade se na dijelovima autoceste koje su u nasipu, u svrhu povezivanja postojećih prometnica i putova koji se presijecaju izgradnjom autoceste. Širine su od minimalno četiri metra do 20 metara. U pravilu su premali da bi ih vuk mogao koristiti (Huber i sur., 2002).

2) Prijelazi

Grade se iznad autocesta, dužine od 30 do 70 metara, a širine isto kao kod prolaza. Uređeni prijelazi sa ogradama su vrlo bitni jer sprječavaju životinju pri prelasku ceste i usmjeravaju na prijelaz uređen u skladu s okolišem. U pravilu su premali da bi ih vuk mogao koristiti (Huber i sur., 2002).

3) Vijadukti

Grade se zbog savladavanja prirodne depresije u terenu prilikom gradnje autoceste. Minimalna duljina vijadukata mora biti preko 100 m iz razloga što ispod onih manje dužine, nema vegetacije i bučan je prolaz te će ih vuk radi toga izbjegavati (Huber i sur., 2002).

4) Mostovi

Grade se zbog savladavanja vodene prepreke. Prilikom uređenja mostova i vijadukata važno je smanjiti utjecaj buke, osvjetljenja i paziti da budu što više u prirodnom okolišu (Huber i sur., 2002).

5) Tuneli

Tuneli predstavljaju najbolje koridore, jer se njihovom gradnjom ne remeti stanište vukova i očuva se prirodna vegetacija. Omogućuju migracijske putove i imaju

najbolju zvučnu i vizualnu izolaciju (Slika 14.). Kod tunela duljih od 200 metara životinja neće osjetiti promet kod prelaženja preko sredine hrpta (Huber i sur., 2002).



Slika 14. Tunel Brinje ( izvor: [http://www.gin.hr/hr/projekti/infrastruktura/tunel-brinje-\(autocesta-zagreb---split\),51.html](http://www.gin.hr/hr/projekti/infrastruktura/tunel-brinje-(autocesta-zagreb---split),51.html))

#### 6) Zeleni mostovi

Zeleni most je betonska struktura zasipana zemljom koja omogućava rast stabala i predstavlja umjetno nadsvođeni dio ceste. Most se mora pošumiti autohtonom vegetacijom kako ne bi bilo otvorenih prostora preko kojih bi životinja mogla prolaziti. Gusto grmlje poslužit će kao zvučna i vizualna izolacija prema cesti. Zeleni mostovi omogućuju neometano prelaženje i migracije preko prometnih infrastruktura svim vrstama, od kukaca pa do velikih sisavaca. Širina mosta mora biti minimalno 100 metara da bi ju vuk iskoristio kao prijelaz.

Primjer zelenog mosta kod nas je most Dedin kod Delnica širine 100,5 metara. Ondje je monitoringom dobiven podatak od 6442 prijelaza godišnje (Huber i sur., 2002).

Infracrvenim senzorima (Slika 15.), kamerama i tragovima (u pijesku ili blatu) treba stalno pratiti koliko životinje koriste prijelaze i bilježiti smrtnost na autocesti (Huber, 2001).



Slika 15. IC senzori i kontrolna traka na zelenom mostu Osmakovac (izvor: <http://www.drypis.info/2006/ZelenimostOsmakovac/tabid/196/Default.aspx>)

Znakovi prijelaza za životinje postavljaju se kod samog prijelaza ili na 300 m udaljenosti od njega, u svrhu upozorenja da su na tim prostorima zabranjene ljudske djelatnosti (Anonymous, 2016).

#### 1.6. Očuvanje populacije velikih zvjeri

Velike zvjeri važno je sačuvati jer:

##### 1) pokazatelji su bogatstva i očuvanja prirode

- Hrvatska je jedna od rijetkih zemalja u Europi gdje još nalazimo sve tri vrste velikih zvjeri (Jeremić i sur., 2011)

##### 2) ključne su vrste koje održavaju prirodnu ravnotežu

- kao predatori na vrhu hranidbene mreže najviše utječu na prirodnu selekciju
- krovne su vrste jer njihovim očuvanjem pridonose očuvanju ostalih vrsta i staništa (Jeremić i sur., 2011)

##### 3) mogućnost za razvoj ekoturizma

- prepoznavanje tragova velikih zvjeri u prirodi može privući brojne turiste što im pruža nezaboravan doživljaj (Jeremić i sur., 2011).

Osim gore navedenog za očuvanje vuka postoje i mnogi ekološki razlozi. Utječe na poboljšanje ekosustava: svojom prehranom tj. hranjenjem strvinama sprečava širenje bolesti (češće lovi životinje koje su oslabljene zbog starosti, bolesti, izgladnjenosti), utječe na prostornu organizaciju populacija plijena, na opće zdravlje populacije plijena i smanjuje štetu nad šumom (Boitani, 2000).

### 1.7. Cilj istraživanja

U ovom će se diplomskom radu izraditi model i kartografski prikaz koji se može upotrebljavati za procjenu utjecaja budućih prometnih i drugih infrastruktura na koridore kretanja vuka, a time će pridonositi i samoj zaštiti vuka. Model može biti upotrebljavan za izradu plana upravljanja vukom, ali i koristan za upravljanje ostalim velikim zvijerima. Pokazat će nam kako pojedini činitelji staništa vuka (npr. nadmorska visina i udaljenost od cesta) utječu na potencijalnu rasprostranjenost populacije vuka. Pomoću modelu moći će se optimalnije planirati buduće gradnje infrastruktura.

## 2. MATERIJALI I METODE

### 2.1. Modeliranje distribucije vrsta

Prediktivno modeliranje prostorne rasprostranjenosti vrsta temeljeno je na okolišnim uvjetima u lokacijama prisutnosti određenih vrsta (Phillips i sur., 2006). Modeli procjenjuju vjerojatnost pojave vrste temeljeno na njihovoj ovisnosti o okolišnim varijablama (Elith i sur., 2011). Predstavljaju veliku važnost u analitičkoj biologiji s primjenama za očuvanje, ekologiji, evoluciji, upravljanju invazivnim vrstama i u mnogim drugim poljima znanosti (Phillips i sur., 2006). Razlika između metoda je u tipu podataka koju koriste za modeliranje (Elith i sur., 2011). Podatci o prisutnosti-odsutnosti vrste i podatci samo o prisutnosti. Dostupnost podataka o prisutnosti vrste je velika te ih najviše nalazimo u prirodoslovnim muzejima i herbarijima, dok su podatci o odsutnosti vrsta rijetki i mogu biti upitne vrijednosti. Upravo zato je modeliranje temeljeno samo na podacima o prisutnosti vrsta od velike važnosti (Phillips i sur., 2006). Postoji niz metoda za modeliranje samo s podacima o prisutnosti vrsta. Maxent je jedna od tih metoda (Elith i sur., 2011).

#### 2.1.1. Maxent

Maxent pronalazi geografska područja s pogodnim okolišnim uvjetima za pojedine vrste, temeljenim na podacima o prisutnosti vrste i okolišnim uvjetima tih lokaliteta (Shcheglovitova i Anderson, 2013). Maxent procjenjuje vjerojatnosti distribucije na način da pronalazi vjerojatnosti distribucije maksimalne entropije, podvrgnute nizu ograničenja koje predstavljaju naše nepotpune informacije o distribuciji vrste (Phillips i sur., 2006).

Princip maksimalne entropije možemo primijeniti na distribuciju vrsta zbog termodinamičkih teorija koje opisuju ekološke procese. Temeljeno na drugom zakonu termodinamike procesi u sustavima gdje nema vanjskih utjecaja, gibaju se u smjeru koji maksimalizira entropiju. Geografska distribucija vrsta težit će distribuciji maksimalne entropije kada utjecaja, osim onih koji nisu uključeni kao ograničenja modela, nema (Phillips i sur., 2006).

Modeli kao GLMs, GAMs, Bayesian pristup imaju mnoge sličnosti, ali i bitne razlike s Maxentom, zbog čega dobivamo i različita predviđanja. GLM/GAM modeli u nedostatku podataka o odsutnosti vrste, uzimaju pozadinske piksele umjesto pravih podataka te takvi rezultati moraju biti interpretirani kao relativni indeksi okolišne pogodnosti. Maxent



nasuprot njima daje model gdje nikada ne koristi piksele bez podataka o vrsti kao prave podatke o odsutnosti vrste (Phillips i sur., 2006).

Kada koristimo podatke samo o prisutnosti vrste za potrebe modeliranja, lokaliteti pojavljivanja vrsta mogu biti pristrani („biased“). Razlog tome je uzimanje uzoraka tj. točaka pojavljivanja u lokacijama do kojih se lakše dolazi kao što su područja bliže gradovima, cestama, rijekama ili drugih objekata u blizini (Phillips i sur., 2009). Također su moguće pogreške u transkripciji, nedostatak geografskih detalja o lokalitetima ili kriva identifikacija vrsta (Shcheglovitova i Anderson, 2013). Maxent radi na principu nepristranosti podataka, stoga može upotrijebiti pozadinske podatke sa sličnom razinom pristranosti ili upotrijebiti „bias grid“ koji će ukazivati na pristranost podataka, ukoliko se izvorni podatci pokažu pristrani (Elith i sur., 2011). Pozadinski podatci moraju obuhvaćati cijeli raspon okolišnih uvjeta vrsta, ali i isključiti sve lokacije koje nisu bile istraživane (Elith i sur., 2011).

Prednosti korištenja Maxenta (Phillips i sur., 2006) :

- 1) Potrebni su mu samo podatci o prisutnosti vrste zajedno s informacijama o okolišnim uvjetima.
- 2) Može iskoristiti i kategorične podatke.
- 3) Vjerojatnost distribucije ima sažetu matematičku definiciju i stoga je pogodna za analizu. U slučaju odsutnosti interakcija varijabli model nam omogućuje da protumačimo kako se svaka okolišna varijabla povezuje s pogodnosti staništa.
- 4) Produkt modela je kontinuiran što nam omogućuje vidjeti male razlike između modela na različitim staništima.
- 5) Maxent ima generativni pristup što mu daje prednost kada je količina podataka za upotrebu „treniranja“ ograničena.

Također postaje i neki nedostaci modela (Phillips i sur., 2006):

- 1) Nije toliko razvijen poput statističke metode kao što su GLM ili GAM te zato nalazimo manje uputa za njegovo korištenje kao i manje metoda za procjenu pogrešaka u predviđanju.
- 2) Izbjegavanje pretreniranosti zahtijeva daljnje i detaljnije proučavanje programa.
- 3) Potreban je poseban softver jer Maxent nije dostupan u standardnim statističkim paketima.

Rezultati Maxenta ovise o kompleksnosti modela, ali i o tome kako se podatci podudaraju s pretpostavkama. Pitanja oko Maxenta odnose se na pretreniranost: kako prepoznati previše kompleksne modele i namjestiti postavke koje vode optimalnoj kompleksnosti. Pretreniranost se događa kada model uklapa podatke o kalibraciji preblizu i zato ne predviđa točno nezavisne podatke za procjenu (Radosavljevic i Anderson, 2014).

#### 2.1.1.1. ROC krivulja i AUC područje

Izvedba modela procijenjena je ROC krivuljom (Receiver Operating Characteristic curve). Točnije područje ispod ROC krivulje, AUC područje široko je prihvaćena vrijednost za procjenu točnosti predviđanja modela (Fielding i Bell, 1997). Za procjenu modela temeljnog na podacima o prisutnosti i pozadinskim podacima umjesto onima o odsutnosti vrste, AUC kvantificira vjerojatnost da je model ispravno rangirao nasumičnu lokaciju prisutnosti vrste više od nasumičnog pozadinskog piksela. AUC varira ovisno o veličini regije proučavanja i zato ju ne možemo koristiti za usporedbu između različitih vrsta ili različitih regija proučavanja. U diplomskom ću radu koristiti samo podatke o jednoj vrsti koja se proteže na području Hrvatske, stoga su vrijednosti AUC-a pogodne za procjenu (Radosavljevic i Anderson, 2014).

Vrijednosti AUC dijelimo ovako (Yost i sur., 2008):

0,9-1 izvrstan model

0,8-0,89 vrlo dobar model

0,70-0,79 osrednji model

0,60-0,60 slabiji model

0,50-0,59 loš model (model nije bolji od slučajnog predviđanja)

Iako mnoge studije preporučuju upotrebu AUC vrijednosti za procjenu uspješnosti modela, sve se više među autorima počinje kritizirati upotreba AUC-a kao standardna mjera točnosti modela distribucije.

Razlozi tome su :

- 1) Vrednuje propust i pogreške jednako (nemaju uvijek istu vrijednost za model)
- 2) Ne daje informacije o pogreškama u prostornoj distribuciji modela
- 3) Ne kvantificira pretreniranost modela
- 4) Vrijednosti variraju ovisno o veličini područja proučavanja.

Upravo zbog tih razloga uz AUC vrijednosti izračunala sam i AIC vrijednosti da bih dobila najbolji mogući model (Lobo i sur., 2008).

## 2.2. ENM Tools

ENM (Environmental Niche Model) su modeli koji koriste podatke o prisutnosti vrste zajedno s ekološkim slojevima. Dobiveni rezultat odgovara ekološkim zahtjevima vrste te predviđa relativnu podobnost staništa. ENM Tools (autori programa su Dan L. Warren, Richard E. Glor i Michael Turelli) je program koji sam koristila za izračun vrijednosti AIC-a (Burnham i Anderson, 2002; Warren i Seifert, 2011).

### 2.2.1. AIC

AIC (Akaike Information Criteria) je kriterij za odabir najboljeg modela među ponuđenima. Najbolji model je onaj koji smanjuje gubitak podataka kod približavanja stvarnosti. AIC nalazi model koji je najbliži istini s najmanje odabranih parametara. AIC podatak sam po sebi nema značenje, ali kada ga se usporedi s većim brojem modela, model s najnižim AIC rezultatom je određen kao najbolji među ponuđenima (Anderson i Burnham, 2002).

Govori nam koliko dodavanje parametara u model povisuje vjerojatnost ishoda i kako pojednostavljenje modela utječe na krajnji rezultat. Neovisan je o distribuciji podataka kroz promatranu regiju i o količini podataka kojim raspolažemo. Odabir modela prema AIC vrijednosti je objektivan. Vrijednosti AIC-a su velike zbog velike količine podataka. Analizirajući AIC vrijednosti dobivene za preko 20 modela koje sam provela u Maxentu odabrala sam onaj koji mi je dao najmanju AIC vrijednost (Franklin, 2010). AIC vrijednosti izračunala sam pomoću ENM Toolsa.

### 2.3. GIS (Geografski Informacijski Sustav)

Geografski informacijski sustavi su računalni sustavi za upravljanje prostornim podacima te analizu njihovih značajki. GIS nam omogućava spremanje, pretraživanje, održavanje, obnavljanje, analizu, statističku obradu i ispis velikog broja različitih podataka u različitim oblicima. To je sustav o cjelokupnom Zemljinom prostoru pa kao takav obuhvaća litosferu, hidrosferu, biosferu i atmosferu. Upravo radi toga upotrebljavaju ga geolozi, hidrolozi, šumari... Međusobno oni dijele prostorne podatke, razmjenjuju dio informacija zajedničkog interesa, a postoje i podatci karakteristični za određenu djelatnost ili ustanovu. (Pahernik, 2006). Povezujući ekološke parametre s prostornim podacima možemo izraditi karte i modele vezane uz ekologiju nekog područja. Osim za analize staništa, GIS se koristi i za razvijanje modela pojava u prirodi, upravljanje nacionalnim parkovima, modeliranje karata rasprostranjenosti, predviđanje utjecaja klimatskih uvjeta na staništa. Najvažnija upotreba u ekologiji i upravljanjem zaštićenih vrsta je planiranje zaštićenih područja, praćenje migracije životinja i utjecaj izgradnje novih prometnica na živi svijet kao i na okoliš (Jelaska, 1997).

Osnovni preduvjet za postojanje i upotrebu GIS-a vezanost je bilo koje vrste podatka s pripadajućim geografskim koordinatama, bilo da se radi o pripadnosti podatka točkastom geografskom entitetu ili određenom području (biotop, planina, županija, nacionalni park, UTM ili MTB kvadrant) (Jelaska, 1997).

### 2.4. Područje istraživanja

Model staništa vuka uključen u ovo istraživanje napravljen je na području Republike Hrvatske. Zahvaljujući svojem geografskom položaju, Hrvatska je na raskrižju nekoliko bio-geografskih regija. Velika raznolikost vrsta, ali i kopnenih, morskih i podzemnih staništa rezultat su karakterističnih ekoloških, geomorfoloških i klimatskih uvjeta. U Hrvatskoj su prisutne četiri regije: panonska, kontinentalna, alpska i mediteranska (Slika 16) (Radović i sur., 2009).



Slika 16. Bio-geografske regije Hrvatske : panonska, kontinentalna, alpska i mediteranska regija. Plavo- mediteranska regija, ljubičasto- alpska regija, zeleno- kontinentalna regija, smeđe- panonska regija (izvor: Radović i sur., 2009)

Prostrane planinske šume bukve i jele staništa su većih populacija vuka i ostalih velikih zvijeri. Šumske površine zauzimaju 47,5 % ukupnog teritorija Hrvatske. Od tog postotka 37 % čine guste šume dok ostatak čine degradirane šumske vegetacije. Na području Gorskog kotara i Velebita nalaze se najveći šumski kompleksi s dominantnim vegetacijama bukve i jele. Nacionalna klasifikacija staništa u Hrvatskoj uz šume definira staništa: površinske kopnene vode i močvarna staništa, neobrasle i slabo obrasle kopnene površine, travnjake, cretove i visoke zelene šikare, šume, morske obale, mora, podzemlja, kultivirane nešumske površine, staništa s korovnom i ruderalnom vegetacijom, izgrađena industrijska staništa i komplekse (Radović i sur., 2009).

Mediteranska regija prostire se područjem koje je pod utjecajem Jadranskog mora i sredozemne klime. Dijelimo ju na obalni i brdski pojas. Regija obuhvaća zimzelene i listopadne šume jadranskog područja (šume alepskog bora, šume hrasta crnike, šume bijelog graba i hrasta medunca, šume crnog graba, šume dalmatinskog crnog bora te šume crnike i crnog graba). Šumska vegetacija stoljećima je krčena kako bi se dobile oranice, pašnjaci, livade i prostor za naselja. Iz tog razloga šume postoje na vrlo malim površinama. Veće površine zauzima degradirani šumski pokrov u kojem dominira makija, garig, šikara i kamenjar. Brdsko planinski krajolici s unutarnjim visoravnima visine između 200 i 500 metara nadmorske visine, karakteristični su za ovo područje (Alegro, 2000).

Alpska regija prostire se planinskim područjima od Sredozemnog mora do zapadnog Sibira (Halavuk, 2013). Dinaridi se protežu ovom regijom uzduž obale Jadranskog mora. Prevladavaju šume jele i smreke. Sačuvani su veći šumski kompleksi zbog manjeg utjecaja čovjeka (Alegro, 2000). Područje Gorskog kotara ima raznoliku klimu zbog mediteranskog, kontinentalnog, alpskog i dinarskog utjecaja. Umjereno hladna klima, velika pokrivenost snijegom i velika količina oborina prevlada ovim područjem (Kusak i sur., 2009).

Kontinentalna regija proteže se na prostoru sjeverne, sjeverozapadne i sjeveroistočne Hrvatske. Kontinentalna klima uz velike rijeke Dunavskog sliva ima veliki utjecaj na regiju. Papuk, Psunj, Krndija, Moslavačka gora, Medvednica i Žumberak nalaze se ovom području (Halavuk, 2013).

Panonska regija pruža se uz krajnji sjeveroistočni dio Hrvatske. Pod utjecajem je suho-stepske klime što ju čini posebnim panonskim sektorom Hrvatske. Primarnu vegetaciju ne čine šume, nego stepski travnjaci, koji su do danas gotovo u cijelosti pretvoreni u plodne obradive površine (Alegro, 2000).

Upravo zbog različitih ekoloških uvjeta, staništa i različite rasprostranjenosti populacije vukova, pri izradi modela staništa vuka, Hrvatsku sam podijelila na dva područja. Za svako područje posebno sam izradila model distribucije vuka. Prvo područje obuhvaćalo je panonsku, kontinentalnu, alpsku te dio mediteranske Hrvatske (Istra i sjeverno Hrvatsko primorje). Drugo područje obuhvaćalo je ostatak mediteranske regije Hrvatske (južno Hrvatsko primorje).

## 2.5. Prikupljeni podatci o vukovima u Hrvatskoj

Podatci koje sam koristila za izradu modela staništa vuka, sakupljeni su u razdoblju od 1998.-2015. godine telemetrijskom metodom praćenja na području Hrvatske. GPS ogrlice omogućile su učestalo praćenje dnevnih, sezonskih i godišnjih kretanja pojedinog obilježenog vuka. Zbog učestalog slanja signala lokacija vukova dobili smo podatke o njihovom kretanju.

Osim GPS ogrlica u počecima praćenja vukova korištene su VHF ogrlice. Položaj vukova s VHF ogrlicama bio je određen triangulacijskom metodom. Pomoću VHF prijamnika i antene radila se triangulacija, tako da se s više različitih točaka odredio smjer iz kojeg dolazi signal.

Lokacije pronađenih izmeta, grebanja, uhvaćenih živih vukova, otisaka šapa, pronađenih mrtvih životinja i viđenja vukova, zabilježena su opažanja koja su korištena kao ulazni podaci u izradi modela staništa.

## 2.6. Ekološke varijable

Pretpostavljeno je da početnih 13 ekoloških slojeva imaju potencijalni utjecaj na model staništa: nagib terena, Shannonov indeks, udio poljoprivrednih površina, udio pašnjaka, nadmorska visina, broj vrsta plijena (parno-prstaša), gustoća ceste, indeks razvedenosti terena, gustoća stanovnika, udio šume, udaljenost od naselja, udaljenost od ruba šume i udaljenost od cesta. Ekološke slojeve u GRID formatu ustupio mi je Zavod za biologiju Veterinarskog fakulteta Sveučilišta u Zagrebu, isključivo u svrhu izrade ovog diplomskog rada.

Udaljenost od naselja predstavlja udaljenost do najbližeg sela ili grupiranih kuća. Udaljenost od ceste predstavlja udaljenost do najbliže ceste uključujući i makadam. Udaljenost od ruba šume predstavlja udaljenost do najbližeg ruba šume koji se nalazi izvan šume.

Podatci koji su korišteni za izradu ovih varijabla, dobiveni su iz raznih izvora (Tablica 1).

Tablica 1. Popis izvora korištenih rastera u izradi modela

PARAMETRI STANIŠTA	IZVOR	NAPOMENA
Udio poljoprivrednih površina (%)	Kusak, J., D. Singer, and S.Desnica. 2005. Vjerojatnost pojavljivanja vuka u Hrvatskoj. LIFE III VUK projekt, GIS karta, DZZP.	Podloga generirana u sklopu zajedničkog (DZZP i VEF) LIFE projekta.
Broj vrsta parnoprstaša	Kusak, J. and K. Krapinec (2010). Ungulatesandtheirmanagementin Croatia. Europeanungulatesandtheirmanagementinthe 21st century. M. Apollonio, R. Andersen and R. Putman. New York, CambridgeUniversityPress 604 pp.: 527-539	Podatci objavljeni u navedenoj knjizi. Izvorne karte su kod autora.
Gustoća cesta (km/km2)	Kusak, J., D. Singer, and S. Desnica. 2005. Vjerojatnost pojavljivanja vuka u Hrvatskoj. LIFE III VUK projekt, GIS karta, DZZP.	Podloga generirana u sklopu zajedničkog (DZZP i VEF) LIFE projekta.
Udio pašnjaka(%)	Kusak, J., D. Singer, and S. Desnica. 2005. Vjerojatnost pojavljivanja vuka u Hrvatskoj. LIFE III VUK projekt, GIS karta, DZZP.	Podloga generirana u sklopu zajedničkog (DZZP i VEF) LIFE projekta
Gustoća stanovnika (n/km2)	Kusak, J., D. Singer, and S. Desnica. 2005. Vjerojatnost pojavljivanja vuka u Hrvatskoj. LIFE III VUK projekt, GIS karta, DZZP.	Podloga generirana u sklopu zajedničkog (DZZP i VEF) LIFE projekta
Udio šume (%)	Kusak, J., D. Singer, and S. Desnica. 2005. Vjerojatnost pojavljivanja vuka u Hrvatskoj. LIFE III VUK projekt, GIS karta, DZZP.	Podloga generirana u sklopu zajedničkog (DZZP i VEF) LIFE projekta
Udaljenost od šume (m)	Ministarstvo kulture (2004): Karta staništa Republike Hrvatske. Izradio: OIKON d.o.o., Institut za primijenjenu ekologiju.	Ustupljena VEF-u temeljem ugovora ( Klasa: 612-07/08-49/1027, URBROJ: 532-08-08-4)
Udaljenost od ceste (m)	Kusak, J., D. Singer, and S. Desnica. 2005. Vjerojatnost pojavljivanja vuka u Hrvatskoj. LIFE III VUK projekt, GIS karta, DZZP.	Podloga generirana u sklopu zajedničkog (DZZP i VEF) LIFE projekta
Udaljenost od naselja (m)	Ministarstvo kulture (2004): Karta staništa Republike Hrvatske. Izradio: OIKON d.o.o., Institut za primijenjenu ekologiju.	Ustupljena VEF-u temeljem ugovora ( Klasa: 612-07/08-49/1027, URBROJ: 532-08-08-4)
Nadmorska visina	<a href="http://freegeographytools.com/2010/free-30-meter-resolution-elevation-data-for-most-of-the-world-from-aster-gdem">http://freegeographytools.com/2010/free-30-meter-resolution-elevation-data-for-most-of-the-world-from-aster-gdem</a>	Slobodno dostupni podatci
Nagib terena	<a href="http://freegeographytools.com/2010/free-30-meter-resolution-elevation-data-for-most-of-the-world-from-aster-gdem">http://freegeographytools.com/2010/free-30-meter-resolution-elevation-data-for-most-of-the-world-from-aster-gdem</a>	Slobodno dostupni podatci, dobiveno iz DEM-a, tj. nadmorskih visina obradom u GIS-u
Indeks razvedenosti terena	<a href="http://freegeographytools.com/2010/free-30-meter-resolution-elevation-data-for-most-of-the-world-from-aster-gdem">http://freegeographytools.com/2010/free-30-meter-resolution-elevation-data-for-most-of-the-world-from-aster-gdem</a>	Slobodno dostupni podatci, dobiveno iz DEM-a, tj. nadmorskih visina obradom u GIS-u
Shannon indeks	<a href="http://www.eea.europa.eu/publications/CORO-landcover">http://www.eea.europa.eu/publications/CORO-landcover</a>	Slobodno dostupni podatci, dobiven iz CORINE landcover obradom u GIS-u



### 2.6.1. Korelacija između varijabla

Korelacija se odnosi na nesamostalnost varijabli i često ju nalazimo kod ekoloških setova podataka. Predstavlja situaciju kada su dvije ili više varijabli u statističkom modelu linearno povezane te taj kolinearni set dijeli veliku količinu informacija (Syfert i sur., 2013). Može predstavljati problem kod procjene važnosti pojedinog parametra i potencijalno dovesti do krive procjene. Značajnosti kolinearnih varijabli tada se ne mogu odvojiti. Spearmanov koeficijent korelacije ( $r$ ) koristimo kod procjene vrijednosti korelacija kada podaci nisu parametrijski (podaci odstupaju od normalne raspodjele) te može iznositi od -1 do +1 (Krpan, 2013). Metoda procjene koja je najviše prihvaćena predstavlja granicu od  $r > 0,7$  kao granica početka korelacije (Dormann i sur., 2013). Dobivene p vrijednosti označavaju statističku vrijednost koeficijenta korelacije te ukoliko iznose manje od 0.05, smatramo da je koeficijent korelacije je značajan i smijemo ga tumačiti (Krpan, 2013). Test sam napravila na svim varijablama i isključila jednu od para koje imaju vrijednost veću od  $r > 0,7$ . U mom slučaju u korelaciji su bili slojevi „šuma“ i „broj vrsta“.

### 2.7. Priprema podataka

Na temelju bio-geografskih regija Hrvatske, ekološke slojeve dobivene u GRID obliku podijelila sam u dva područja. Prvo je područje obuhvaćalo panonsku, kontinentalnu, alpsku te dio mediteranske Hrvatske (Istra i sjeverno Hrvatsko primorje), dok je drugo područje obuhvaćalo ostatak mediteranske regije Hrvatske (južno Hrvatsko primorje). Varijable sam prebacila u raster formate. Dobivene GPS i TNG lokacije također sam podijelila u gore dva navedena područja. Modeliranje koridora u GIS-u radila sam s prediktivnom kartom dobivenom Maxent programom, zajedno s podacima o autocestama i objektima za prijelaz. Kartu postojećih autocesta i postojećih objekata na njima u shapefile formatu ustupio mi je Zavod za biologiju Veterinarskog fakulteta Sveučilišta u Zagrebu. Postojeći objekti uključuju sve prijelaze, prolaze, čvorove, mostove, tunele, vijadukte, zelene mostove, odmarališta, prijelaze kod čvora koji se nalaze na svim autocestama u Hrvatskoj.

Svakom objektu pojedinačno sam izmjerila širinu iskazanu u metrima, pomoću opcije „Measure“ u GIS-u. Objekte širine manje od 80 metara izbacila sam iz završnog rastera jer su se u mnogim znanstvenim istraživanjima pokazali kao nepogodni za korištenje od strane

vuka (Zlatanova i sur., 2010). Širina od 80 metara gledana je iz pogleda životinje koja prolazi pojedini objekt.

## 2.8. Izrada prediktivnog modela staništa

Za izradu prediktivnog modela staništa tj. kartu vjerojatnosti nastanjivanja prostora, kao ulazne podatke, koristila sam podatke o lokacijama vukova i opažanjima zajedno s 13 ekoloških varijabla. „Subsample“ opciju rada Maxenta odabrala sam zajedno s postavkom „Random seed“ koja je namještena na 25 %. Postotak od 25% nam govori da kod svakog ponavljanja rada Maxenta (broj ponavljanja namjestila sam na 15), 25% točaka o prisutnosti vrste bilo je upotrijebljeno kao test točke. Izradila sam datoteku nazvanu „bias file“ zbog pristranosti podataka, koja je također korištena kao jedna od varijabla. Bias file sam izradila zasebno za gornji dio Hrvatske (uključuje kontinentalnu, panonsku, alpsku i sjeverno Hrvatsko primorje mediteranske regije) i zasebno za donji dio (uključuje južno Hrvatsko primorje mediteranske regije). „Bias file“ sadržavao je pozadinske pseudo podatke o odsutnosti vrste sa lokacija gdje su zabilježene točke o prisutnosti vrste (Phillips i sur., 2009). Model staništa napravljen je za svako područje posebno. Dobivene karte modela zatim sam spojila u jednu cjelovitu kartu Hrvatske kao završni produkt Maxenta. Nakon provedbe programa izabrala sam pet ekoloških varijabli koje pridonose najviše karti pogodnosti staništa. Nadalje sam koristila tih pet varijabli, jer su se pokazale kao najznačajnije i s najvećim utjecajem na završni oblik karte, zajedno s lokacijama aktivnosti i opažanjima prisutnosti vukova. Korištene varijable bile su: broj vrsta plijena (parno-prstaša), nadmorska visina, udaljenost od ceste, udaljenost od naselja i udaljenost od šume. Prediktivni model staništa podijelila sam u devet kategorija, jednako kao i Kusak i sur. (2016), radi kompatibilnosti, a koje su pokazivale prikladnost tj. osjetljivost staništa (Tablica 2).

Tablica 2. Vjerojatnosti (%) prisutnosti vuka, klasificirane u devet klasa, a koje su onda svedene na četiri kategorije. Za prikaz klasa staništa na kartama korištena je legenda boja prikazana u drugoj koloni tablice.

VJEROJATNOST (%) PRISUTNOSTI VUKA	KLASA I LEGENDA	KATEGORIJA (ZNAČAJ)
0-5	1	NEPRIKLADNO
5-10	2	
10-20	3	
20-30	4	NISKA PRIKLADNOST
30-40	5	
40-50	6	
50-65	7	SREDNJA PRIKLADNOST
65-80	8	
80-100	9	

## 2.9. Modeliranje koridora kretanja vukova

Dobivenu kartu pogodnosti staništa iz Maxenta koristila sam u GIS softveru, za modeliranje koridora kretanja vukova. Opcijom „least cost path“ u ArcMapu dobila sam put koji pokazuje najmanji „trošak“ za životinju pri prijelazu s točke A do točke B. Određujući najpovoljniji put uzeta je u obzir karta pogodnosti (osjetljivosti) staništa s postojećom kartom autocesta i povoljnih objekata prijelaza na njima (svi širi od 80 metara). Odabrane točke prijelaza postavila sam sa svake strane pojedine autoceste. Većinu točaka postavila sam u područja koja su na karti staništa pokazivale veliku prikladnost distribucije vrsta.

Autoceste sam postavila kao nepropusnu barijeru dajući im vrijednosti 1, dok su prijelazi mjesta najveće propusnosti, tj. najveće prikladnosti i imaju vrijednost 9 (Tablica 2.). Dane vrijednosti sukladne su onima koje sam postavila na kartu prikladnosti staništa (1-vrijednost staništa koja su neprikladna, 9-vrijednosti staništa koje imaju visoku prikladnost). Dobiveni koridori odraz su puta koji predstavlja najmanju udaljenost između postavljenih točaka, uzimajući u obzir postotak prikladnosti staništa između njih, udaljenost do najbližeg pogodnog objekta za prijelaz i autoceste kao nepropusne barijere.

### 3. REZULTATI

Većina ekoloških varijabla koje sam provela kroz test Spearmanovog koeficijenta korelacije u R programu, imale su nisku do srednju vrijednost korelacije, osim varijabla „broj vrsta plijena“ i „udio šume“. Uzimajući u obzir da vrijednosti veće od  $r > 0,7$  između dvije varijable stvaraju problem kod procjene važnosti parametra, isključila sam jednu od para varijabli koja je bila u korelaciji (Tablica 3a, 3b). Vrijednosti koeficijenta značajnosti korelacije (p) su bile uvijek bile manje od 0,05, točnije iznosile su  $p < 0,001$  te zato koeficijent korelacije tumačimo kao statistički značajan.

U mom slučaju u korelaciji su bili slojevi „šuma“ i „broj vrsta plijena“ ( $r = 0,95$ ,  $p < 0,001$ ).

Tablica 3a . Spearmanov koeficijent korelacije ekoloških varijabla

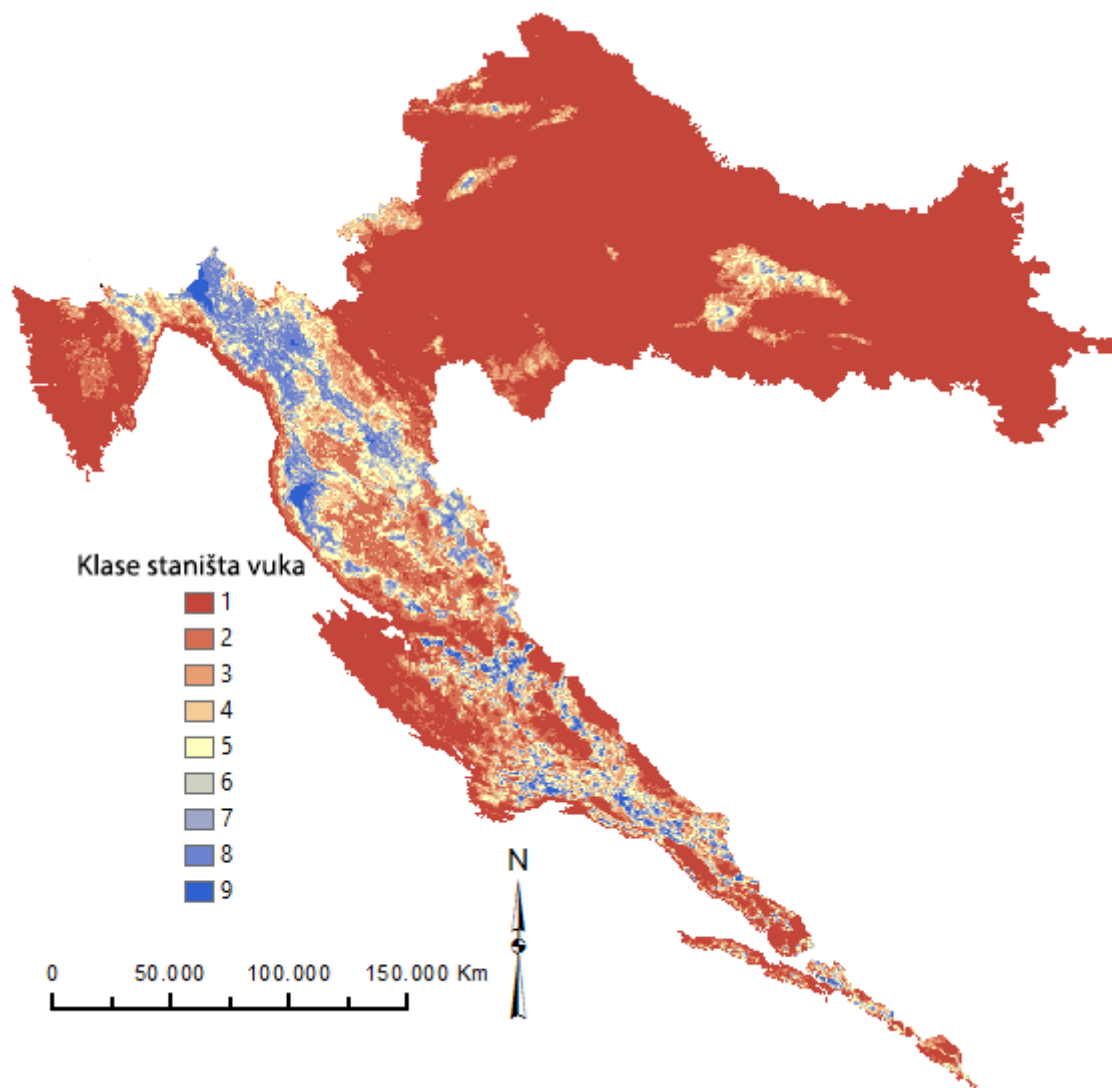
Ekološke varijable	Shannon indeks	Nagib terena (stupnjevi)	Gustoća ljudi (n/km <sup>2</sup> )	Udio šume (%)	Udaljenost od ruba šume (m)	Udaljenost od ceste (m)	Udaljenost od naselja (m)
Udio poljoprivredne površine (%)	0,01	-0,15	-0,01	-0,65	0,01	-0,05	-0,11
Broj vrsta plijena	-0,04	0,01	-0,14	0,95	-0,05	0,01	0,01
Gustoća ceste (km/km <sup>2</sup> )	0,01	-0,04	0,27	-0,16	0,01	-0,03	-0,05
Indeks razvedenosti terena	0,00	0,16	-0,01	0,00	0,00	0,00	0,02
Udio pašnjaka (%)	0,03	0,17	-0,08	-0,37	0,04	0,08	0,12
Nadmorska visina (m)	-0,02	0,23	-0,10	0,36	-0,07	0,10	0,16
Shannon indeks	1	0,02	-0,01	-0,04	-0,01	-0,02	-0,05
Nagib terena (stupnjevi)	0,02	1	-0,07	0,02	-0,09	0,06	0,10
Gustoća ljudi (n/km <sup>2</sup> )	-0,01	-0,07	1	-0,15	0,01	-0,03	-0,02
Udio šume (%)	-0,04	0,02	-0,15	1	-0,04	-0,01	0,02
Udaljenost od ruba šume (m)	-0,01	-0,09	0,01	-0,04	1	-0,02	-0,02
Udaljenost od ceste (m)	-0,02	0,06	-0,03	-0,01	-0,02	1	0,45
Udaljenost od naselja (m)	-0,05	0,10	-0,02	0,02	-0,02	0,45	1

Tablica 3b. Spearmanov koeficijent korelacije ekoloških varijabli

Ekološke varijable	Udio poljoprivredne površine (%)	Broj vrsta plijena	Gustoća ceste (km/km <sup>2</sup> )	Indeks razvedenosti terena	Udio pašnjaka (%)	Nadmorska visina (m)
Udio poljoprivredne površine (%)	1	-0,63	0,13	-0,04	-0,31	-0,43
Broj vrsta plijena	-0,63	1	-0,16	0,00	-0,37	0,38
Gustoća ceste (km/km <sup>2</sup> )	0,13	-0,16	1	-0,01	-0,09	-0,13
Indeks razvedenosti terena	-0,04	0,00	-0,01	1	0,05	0,02
Udio pašnjaka (%)	-0,31	-0,37	-0,09	0,05	1	0,14
Nadmorska visina (m)	-0,43	0,38	-0,13	0,02	0,14	1
Shannon indeks	0,01	-0,04	0,01	0,00	0,03	-0,02
Nagib terena (stupnjevi)	-0,15	0,01	-0,04	0,16	0,17	0,23
Gustoća ljudi (n/km <sup>2</sup> )	-0,01	-0,14	0,27	-0,01	-0,08	-0,10
Udio šume (%)	-0,65	0,95	-0,16	0,00	-0,37	0,36
Udaljenost od ruba šume (m)	0,01	-0,05	0,01	0,00	0,04	-0,07
Udaljenost od ceste (m)	-0,05	0,01	-0,03	0,00	0,08	0,10
Udaljenost od naselja (m)	-0,11	0,01	-0,05	0,02	0,12	0,16

Provedbom Maxent programa sa svim početnim varijablama u rezultatima se pokazalo da parametar „broj vrsta plijena“ ima veći utjecaj na model od parametra „udio šuma“. Upravo iz tog razloga varijabla „udio šume“ izbačena je iz završne verzije podataka koje sam koristila za izradu modela staništa.

Kartu pogodnosti staništa, odnosno prediktivni model staništa u Maxent programu, napravila sam posebno za gornji dio Hrvatske tj. nazvano područje 1 (alpsku, kontinentalnu, panonsku i dio mediteranske regije), i posebno za donji dio Hrvatske tj. područje 2 (južno hrvatsko primorje mediteranske regije). Priložena karta (Slika 17.) prikazuje spojene modele staništa u cjeloviti prikaz pogodnosti staništa za cijelu Hrvatsku. Dobivene vrijednosti modela preoblikovane su na raspon od 0-100 %, odnosno 9 kategorija klasifikacije prema smjernicama za procjenu zahvata na velike zvijeri u sklopu planskih dokumenata (Kusak i sur., 2016) (Tablica 2.). Deveta kategorija označava područja s najvećom vjerojatnosti pojavljivanja vukova i staništa, koja se najviše poklapaju s ekološkim uvjetima i lokacijama ulaznih podataka.



Slika 17. Karta pogodnosti staništa vuka u Hrvatskoj. Klasa 1 pokazuje neprikladna područja, klase 2 i 3 - nisku prikladnost, klase 4,5,6- srednja prikladnost, klase 7,8,9- visoka prikladnost.

Relativne vrijednosti doprinosa pojedine varijable razlikuju se kada gledamo zasebno gornji i donji dio Hrvatske za koje je napravljen model (Tablica 4 i 5). Za područje 1 prema postotku doprinosa modelu najvažnija varijabla je udaljenost od naselja. Međutim po permutacijskom značaju i nadmorska visina može biti jako važna za konačni ishod. Kao što vidimo u rezultatima područja 2 nadmorska visina ima najveći utjecaj na model pogodnosti staništa. Što je veći doprinos to je veći utjecaj varijable na predviđanje pojavljivanja vrste na određenom području. Permutacijski značaj pojedine varijable određen je na način da su vrijednosti varijable nasumično mijenjane među treniranim

točkama (točke prisutnosti vrste i pozadinske točke uz njih) te zatim mjerenja nastalog pada vrijednosti u treniranom AUC rezultatu.



Tablica 4. Postotak doprinosa modelu i permutacijski značaj varijabli za područje 1 (alpska, kontinentalna, panonska regija i sjeverno primorje mediteranske regije)

Varijable	Postotak doprinosa modelu	Permutacijski značaj
<b>Udaljenost od naselja</b>	59,6	2,8
<b>Nadmorska visina</b>	27,3	77,7
<b>Broj vrsta plijena</b>	6,8	2,9
<b>Udaljenost od ceste</b>	4,5	9,4
<b>Udaljenost od ruba šume</b>	1,8	7,2



Tablica 5. Postotak doprinosa modelu i permutacijski značaj varijabli za područje 2 (južno Hrvatsko primorje mediteranske regije)


Varijable	Postotak doprinosa modelu	Permutacijski značaj
<b>Nadmorska visina</b>	51,4	55,3
<b>Broj vrsta plijena</b>	29	14,2
<b>Udaljenost od ceste</b>	9,7	9,6
<b>Udaljenost od naselja</b>	7,3	6,6
<b>Udaljenost od ruba šume</b>	2,7	14,3

„Response curves“ nam pokazuju kako pojedina varijabla utječe na mogućnost predviđanja Maxenta. Krivulje pokazuju kako se mijenja pojedina varijabla kada ostavljamo sve ostale varijable na srednjoj vrijednosti. Za područje 1, varijable broj vrsta parnoprstaša, nadmorska visina i udaljenost od naselja su u pozitivnoj korelaciji s vjerojatnosti prisutnosti vrste. Znači da se predviđena pogodnost staništa tj. mogućnost pojavljivanja vrste povećava kako se povećava pojedina vrijednost varijable. Udaljenost od šume i udaljenost od ceste su u negativnoj korelaciji s vjerojatnosti prisutnosti vrste, tako da se mogućnost pojavljivanja vrste smanjuje kako se njihove vrijednosti povećavaju (Slika 18 i 19). U području 2, porastom broja vrsta parnoprstaša raste i vjerojatnost pojavljivanja vuka do određene vrijednosti kada se potencijalno pojavljivanje počinje smanjivati. U dalmaciji vukovi ovise o hrani od čovjeka zbog smanjenog broja prirodnog plijena.















Slika 18. „Response curves“ za područje 1






Slika 19. „Response curves“ za područje 2

U Jackknife testu model je kreiran tako da je pojedina varijabla isključena iz testiranja, a ostale su uključene. Nakon toga, model je napravljen koristeći samo jednu varijablu u izolaciji. Naposljetku su sve varijable uključene u model. Testom možemo utvrditi koja varijabla individualno najviše pridonosi modelu. Za područje 1 udaljenost do naselja ima najveći značaj kada se koristi u izolaciji, što znači da sadrži najviše informacija koje nisu prisutne u drugim varijablama (Slika 20). Za područje 2 nadmorska visina pojedinačno ima najveći značaj pri izradi modela (Slika 21).



Slika 20. Jackknife test područja 1

Broj vrsta plijena- 1  
Nadmorska visina- 2  
Udaljenost do ruba šume- 3  
Udaljenost do ceste- 4  
Udaljenost do naselja- 5



Slika 21. Jackknife test područja 2.

Broj vrsta plijena- 1  
Nadmorska visina- 2  
Udaljenost do ruba šume- 3  
Udaljenost do ceste- 4  
Udaljenost do naselja- 5

Sveukupno model je pokazao vrlo dobro izvedbu za oba područja što nam pokazuje vrijednost AUC (Tablica 5). Visoka AUC vrijednost je za model na test podacima (Test data) i za model s početnim ulaznim podacima ( Training data).

Tablica 5. Rezultati AUC-a za područje 1 i 2

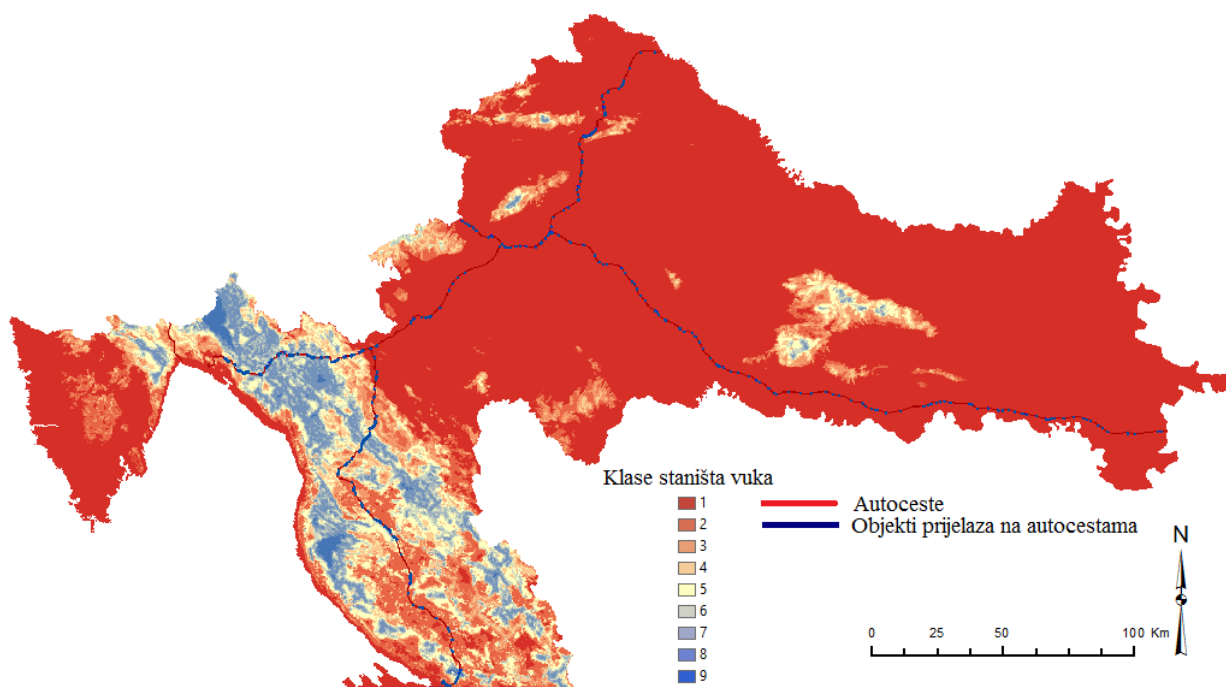
	Training data AUC	Test data AUC
Područje 1	0,865	0,857
Područje 2	0,87	0,837

ENM Tools programom izračunala sam AIC vrijednosti pojedinog modela s različito izabranim parametrima prilikom izrade Maxent modela. Usporedbom napravljenih modela, svaki s različitim parametrima izabrala sam onaj s najnižom vrijednosti (Tablica 6).

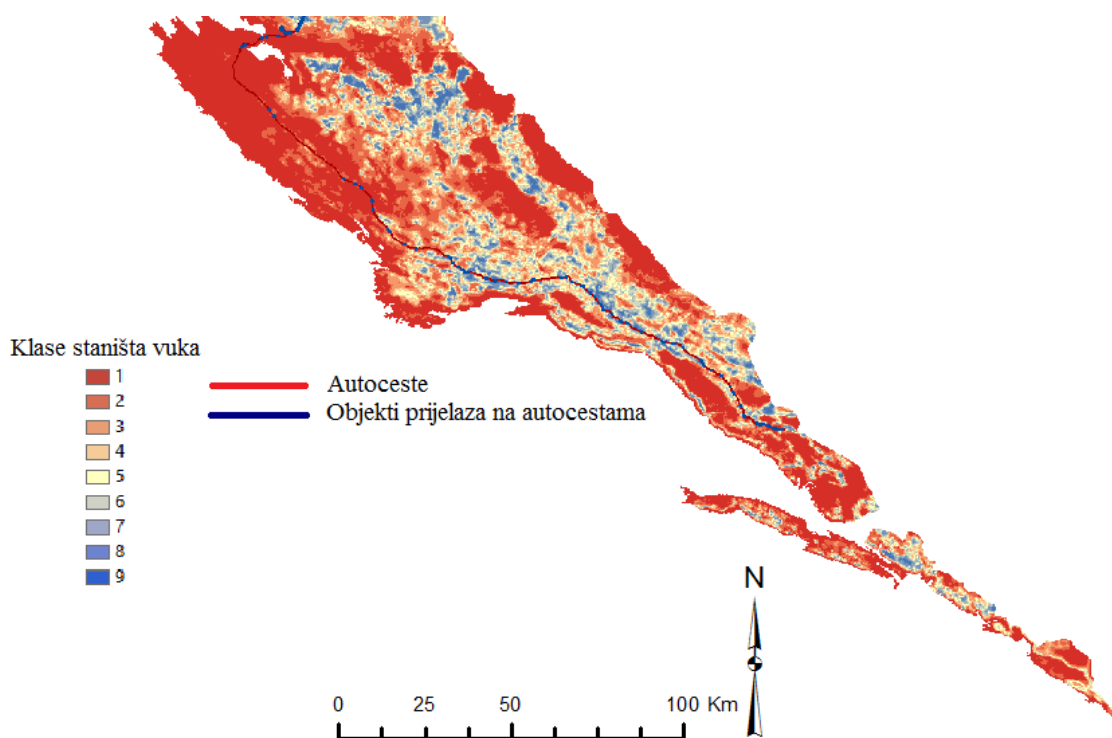
Tablica 6. AIC rezultat odabranog modela pogodnosti staništa vrsta za područje 1 i 2

	Količina uzorka	AIC rezultat
Područje 1	28815	675853,32
Područje 2	1528	32695,36

Model staništa iz Maxenta zatim sam ubacila u GIS softver te spojila s rasterom autocesta i objekata prijelaza koji mogu funkcionirati kao najuži dijelovi koridora kretanja vukova. Autocestama je po tablici osjetljivosti staništa dana vrijednost 1, isto kao i područjima neprikladnim za vuka (Tablica 2) te se one kao takve smatraju kao nepropusna barijera. Objektima za prijelaz dana je vrijednost 9, isto kao staništima visoke prikladnosti za vuka, iz razloga što se smatraju kao područja najveće propusnosti. Rasteri su spojeni u mozaik te ponovno reklasificirani sada i s cestama i s objektima u 9 kategorija prikladnosti staništa. Karta prikazuje područja gdje su autoceste obojane crveno, a postojeći objekti plavo (Slika 22,23).



Slika 22 . Karta područja 1 s ucrtanim autocestama i postojećim objektima prijelaza koji mogu funkcionirati kao najuži dijelovi koridora kretanja



Slika 23 . Karta područja 2 s ucrtanim autocestama i postojećim objektima prijelaza koji mogu funkcionirati kao najuži dijelovi koridora kretanja

## Površine staništa vuka

Nakon reklasifikacije Maxent modela te podjele staništa na klase osjetljivosti, model sam u GIS-u pretvorila u poligone kako bih mogla izračunati kolika je površina svake klase staništa na području Hrvatske (Tablica 7.). U odnosu na shapefile kartu stalne i povremene rasprostranjenosti vuka koji mi je ustupio Zavod za biologiju Veterinarskog fakulteta Sveučilišta u Zagrebu, ponovno sam izračunala površinu svake klase osjetljivosti upravo na tim poznatim područjima prisutnosti (Tablica 8).

Tablica 7. Površine i udjeli klasa osjetljivosti na području cijele Hrvatske, te posebno na području gdje je vuk stalno i povremeno prisutan.

Klase osjetljivosti	Vuk (cijela Hrvatska)		Vuk (područja prisutnosti)	
	Km <sup>2</sup>	%	Km <sup>2</sup>	%
<b>1</b>	34830.35	65	8601.00	35
<b>2</b>	4570.79	8	3551.21	15
<b>3</b>	3289.02	6	2471.52	10
<b>4</b>	2921.15	5	2461.64	10
<b>5</b>	2467.21	4	2190.70	9
<b>6</b>	1576.05	3	1495.27	6
<b>7</b>	1616.95	3	1562.88	7
<b>8</b>	1506.17	3	1466.48	6
<b>9</b>	359.71	3	349.76	2
<b>Ukupno</b>	53147.58	100	24150.46	100

Područja visoke prikladnosti (7, 8, 9) za vuka zauzimaju svega 3482,83 km<sup>2</sup> dok nasuprot tome područja koja nisu pogodna za stanište vuka (1) čini 34830,35 km<sup>2</sup>, odnosno 65 % ukupne površine kopnene Hrvatske. Najveći udio područja nepogodnih za vuka nalazi se na području Zagreba i Središnje Hrvatske, Sjeverozapadne Hrvatske i Istočne Hrvatske.

Veterinarski fakultet Sveučilišta u Zagrebu ustupio mi je i shapefile Hrvatske, odnosno poligon koji je podijelio Hrvatsku na šest različitih područja: Panonska i peripanonska regija, Gorski kotar, Istra i Primorje, Banovina-Kordun-Žumberak, Lika i Velebit, Dalmacija. Sukladno toj podijeli, svakom području izračunala sam ukupnu površinu koju zauzimaju klase osjetljivosti kao i površinu svake klase zasebno.

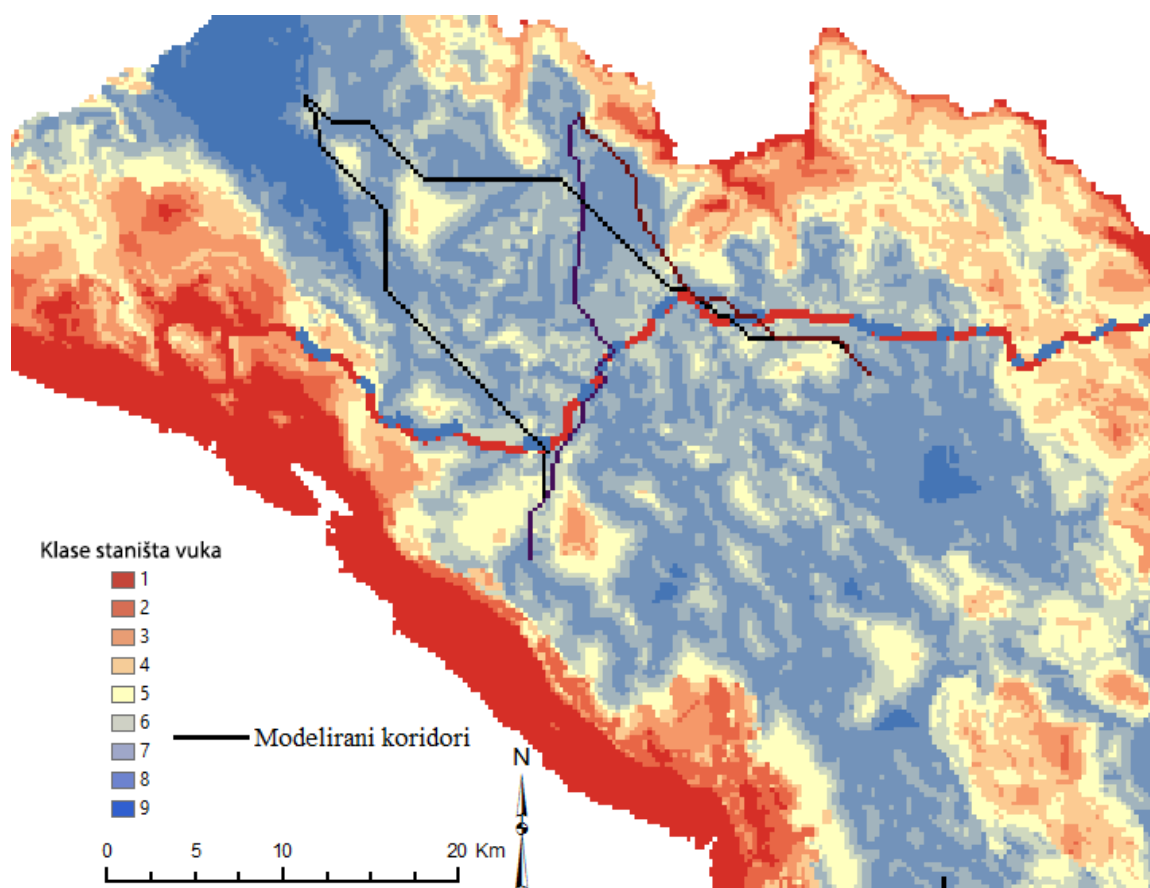


Tablica 8. Površina svake klase zasebno te ukupna površina klasa za 6 različitih područja Hrvatske

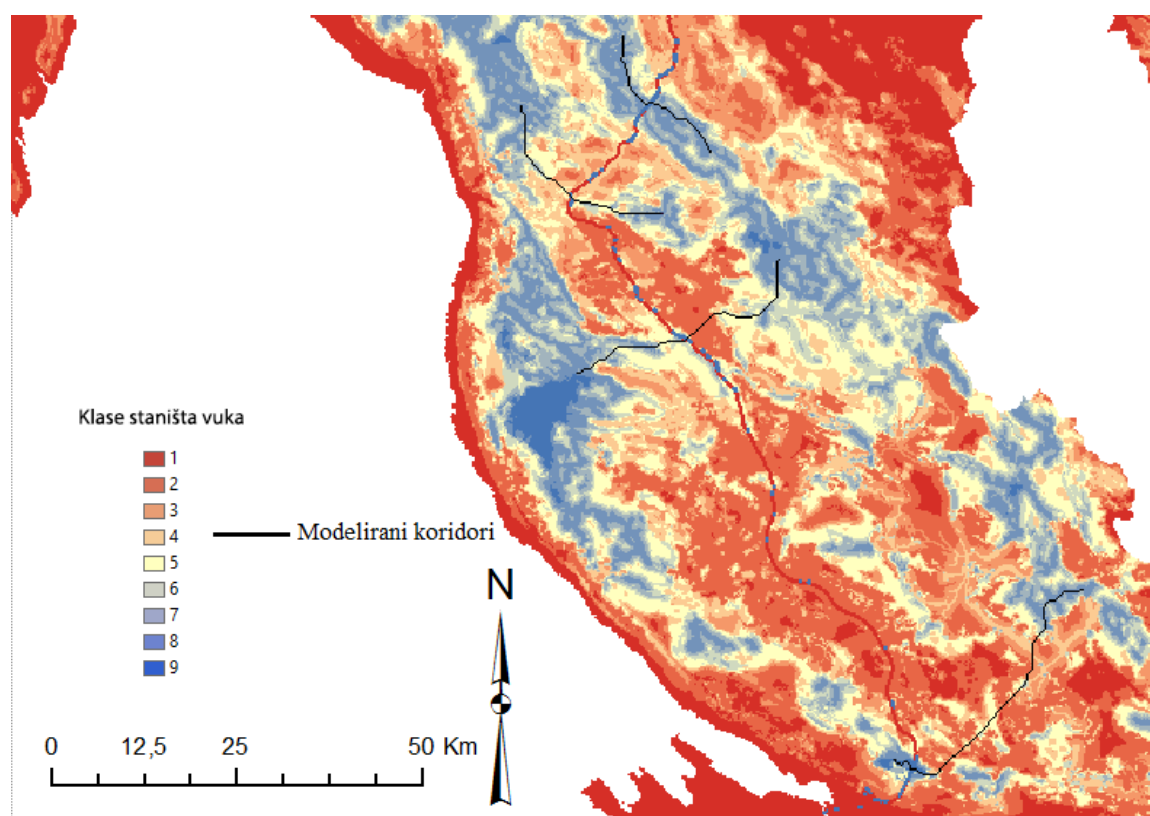
<b>Klase osjetljivosti</b>	<b>Panonska i peripanonska regija (km<sup>2</sup>)</b>	<b>Gorski kotar (km<sup>2</sup>)</b>	<b>Istra i Primorje (km<sup>2</sup>)</b>	<b>Banovina, Kordun, Žumberak (km<sup>2</sup>)</b>	<b>Lika i Velebit (km<sup>2</sup>)</b>	<b>Dalmacija (km<sup>2</sup>)</b>
<b>1</b>	24.8	4.0	23.9	12.6	183.9	750.2
<b>2</b>	436.3	85.0	366.3	326.6	1376.7	1408.4
<b>3</b>	575.8	145.8	215.9	258.4	715.0	999.9
<b>4</b>	357.7	191.9	140.6	115.0	914.9	880.3
<b>5</b>	214.8	243.1	106.0	27.0	980.4	718.8
<b>6</b>	52.9	234.2	44.0	4.2	599.9	568.1
<b>7</b>	35.8	460.7	40.4	4.5	594	399.1
<b>8</b>	18.8	255.1	34.9	0	428.5	326.0
<b>9</b>	0	11.0	0	0	75.9	176.9
<b>Ukupna površina klasa (km<sup>2</sup>)</b>	1716.9	1630.8	972	748.3	5869.2	6227.7
<b>Ukupna površina regije(km<sup>2</sup>)</b>	24360.8	2549.72	3521.54	6362.38	6616.5	9744.98

Rezultati usporedbe sukladni su prostornom rasporedu vuka. Područja s minimalnom površinom područja visoke prikladnosti su Banovina, Kordun i Žumberak, Panonska i peripanonska regija te Istra i Primorje što nam pokazuje i dobiveni model distribucije iz Maxenta. Najprikladnija područja nalazi se u Dalmaciji, Gorskom kotaru, Lici i Velebitu. Područja karakteriziraju veći šumski kompleksi te planinska područja koja su u Hrvatskoj područja stalne prisutnosti vuka.

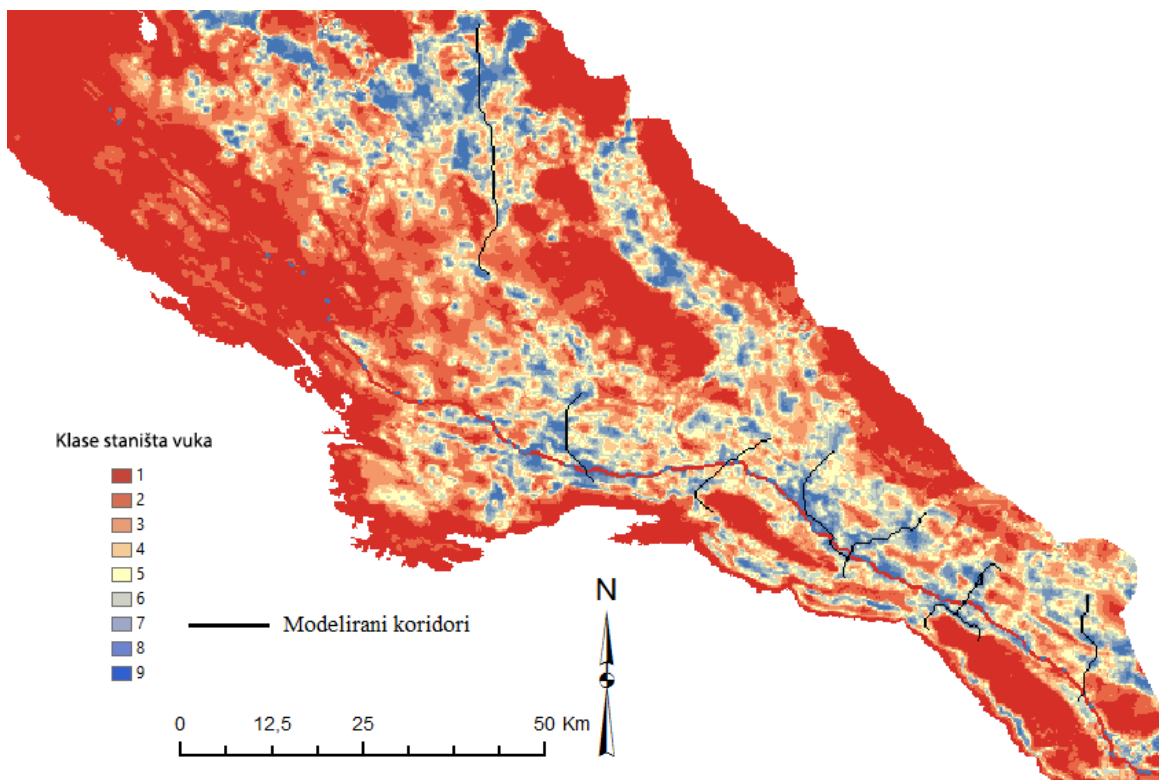
Opcijom „Least cost path“ putem „Cost distance“ i „Cost path“ alata u ArcMapu dobila sam najpovoljnije putove prijelaza s obzirom na nepropusnost cesta i postojeće objekte koji čine prijelaze preko autocesta i čine ih propusnima. Početne i završne točke prijelaza postavljene su na područja visoke prikladnosti s obzirom na staništa s najvećim postotkom vjerojatnosti pojavljivanja vukova, pošto su tamo najpotrebniji koridori (Slika 24-26).



Slika 24. Modelirani koridori na autocesti A6



Slika 25. Modelirani koridori na autocesti A1



Slika 26. Modelirani koridori na autocesti A1

Modelirala sam ukupno 16 koridora od kojih 12 prolazi autocestom A1. Razlog tome je stalna i povremena prisutnost vuka upravo na područjima kroz koje autocesta A1 prolazi. Izrađeni koridori pokazali su najpovoljnije putove kretanja na čiji je smjer najviše utjecala prisutnost crvenog područja, odnosno područja neprikladna za vuka. Iako u većini slučajeva izbjegava takva područja, u situacijama kada je prijelaz predaleko, vuk može ići i preko neprikladnih područja, što nam pokazuje da vuku nije problem prijeći i preko manje kvalitetnih staništa (Slika 25, 26).

#### 4. RASPRAVA

Karta pogodnosti staništa vuka je u skladu s dosadašnjim saznanjima o rasprostranjenosti vuka te sa ranijim modelom staništa (Kusak i sur., 2005). Većina predviđenih područja visoke prikladnosti odgovara trenutnoj karti područja stalne i povremene prisutnosti vuka, posebno područje Gorskog kotara. Dosadašnja saznanja o važnosti pojedinih stanišnih varijabli poklapaju se s relativnim doprinosom dobivenih varijabli modela, gdje je velika važnost broj vrsta plijena te ljudski utjecaj (analizirano varijablama „udaljenost od naselja“ i „udaljenost od ceste“) (Ciucci i sur., 2003).

Model pogodnosti staništa dobiven Maxent programom sveukupno je pokazao vrlo dobru izvedbu dijelom i radi velike količine ulaznih podataka (lokacija vukova). Područje ispod ROC krivulje, odnosno vrijednost AUC-a za oba područja računanja premašuje 0,8, (vrijednost AUC-a za područje 1 bila je 0,865, a za područje 2 0,870) čime pokazuje izvedbu puno bolju od bilo kojeg slučajnog modela (Yost i sur., 2008). Upotreba pozadinskih podataka sa sličnom razinom pristranosti kao ulazni podatci, uvelike je pridonijela višoj vrijednosti AUC-a, što pokazuje koliki problem može biti pristranost podataka u istraživanju (Phillips i sur., 2006). Spearmanov test korelacije pokazao je visoku korelaciju između samo dvije varijable, od kojih je jedna na kraju eliminirana, no ipak neke varijable pokazale su umjerenu korelaciju. Njihova vrijednost nije premašila 0,7 što je uzeto kao prag eliminacije (Dormann i sur., 2013) te su prihvaćene kao pogodne za analizu. Varijable „nadmorska visina“ i „broj vrsta plijena“ u oba područja provedbe Maxenta pokazale su se kao varijable s velikim postotkom doprinosa modelu, no ipak je njihova korelacija umjerena te iz tog razloga njihov doprinos treba s oprezom uzeti u obzir. Relativne vrijednosti doprinosa pojedine varijable razlikuju se kada gledamo područje 1, odnosno kontinentalnu Hrvatsku i kada promatramo vrijednosti područja 2 tj. Dalmaciju. Na sjeveru Hrvatske najveći značaj ima udaljenost od naselja, a u Dalmaciji nadmorska visina. Broj vrsta plijena ima značaj utjecaj na području Dalmacije jer smanjenim brojem prirodnog plijena, vukovi moraju živjeti blizu čovjeka pošto ovise o hrani od čovjeka.

Područje Gorskog kotara, Like i Velebita karakterizira veće nadmorske visine, što ih čini povoljnim staništem za vuka, uz gusti šumski pokrov koji im pruža sklonište. Kako su u prošlosti vukovi bili potisnuti iz nizinskih predjela, tako ih danas najviše nalazimo u planinama, koje im pružaju dovoljni zaklon od ljudi (Štrbenac i sur., 2010). Permutacijski doprinos nadmorske visine nam to i potvrđuje s najvećim postotkom među svim

varijablama. Analizirajući kartu modela dobivenu Maxentom vidimo da su upravo područja veće nadmorske visine ona s najpovoljnijim staništima za vuka. Nadmorska visina je u pozitivnoj korelaciji s prisutnošću vrste, što znači da porastom nadmorske visine raste i vjerojatnost pojavljivanja vuka, iako se nakon visine od 1200 metara vjerojatnost prisutnosti vuka počinje smanjivati. To je sukladno dosadašnjim saznanjima da stanište vukova nije na najvišim planinskim vrhovima (Ciucci i sur., 2003).

Uz pokrivenost staništa šumom na prisutnost vuka najviše utječu prisutnost plijena, ali i njegova dostupnost te razina ljudske aktivnosti (Štrbenac i sur., 2010). Razinu ljudske aktivnosti možemo interpretirati kroz varijablu „udaljenost od naselja“ koja je pokazala veliki utjecaj na model posebno na području kontinentalne Hrvatske. Do određene vrijednosti udaljenost od naselja ne uzrokuje povećanje postotka prisutnosti vukova. Nakon vrijednosti od 6000, kako se povećava udaljenost od naselja povećava se i vjerojatnost pojavljivanja vuka. Razlog obitavanja vuka u relativnoj blizini naselja može biti i podatak da vuk ponekad zalazi na područja gdje je broj ljudi veći, ukoliko ga oni ne uznemiravaju i on se može od njih sakriti (Štrbenac i sur., 2010). Iako vukovi izbjegavaju ljudska naselja, ponekad njihova blizina također znači i blizinu plijena. U odsutnosti prirodnog plijena vuk se može okrenuti i domaćim životinja te se približiti naseljima. Napad na stoku najčešći je u području Dalmacije, jer dostupnost i prisutnost plijena nije uvijek velika te domaće životinje postaju glavni izvor hrane. Svega 5,7 % u Splitsko-dalmatinskoj i 1,3 % u Šibensko-kninskoj županiji zauzima rasprostranjenost parno-prstaša (Štrbenac i sur., 2010). Također domaće životinje lakše je uloviti ako nisu čuvane. Koliko su plijen i njegova dostupnost važni vidimo po relativnom utjecaju varijable „broj vrsta parnoprstaša“ koja pokazuje veliki doprinos modelu. Stanište će biti prikladnije za vuka što je različitiji broj vrsta parno-prstaša (Dupré i sur., 1995). Pad kvalitete staništa u Dalmaciji, smanjenje sveukupnog raspoloživog prostora (najviše zbog eksploatacije šuma koja je dovela do degradiranih i malih šumskih pokrova), razlog su manje vjerojatnosti prisutnosti vrste nego u području Gorskog kotara. Također, zbog ljudske netolerancije na vuka uglavnom zbog napada na stoku populaciju se konstantno nelegalno ubija (Kusak i sur., 2005). Tako je veličina teritorija vučjeg čopora u Dalmaciji otprilike 150 km<sup>2</sup>, dok je u Gorskom kotaru 350 km<sup>2</sup> (Kusak, 2010).

Otoci prikladnih staništa koji se nalaze izvan područja trenutne, stalne ili povremene prisutnosti, nalaze se većinom na području gorja: Papuka, Psunja, Krndije, Požeške gore i Dilja. Također Zrinska gora, Petrova gora, Žumberačko gorje i Samoborsko gorje pokazuju

potencijalna područja pojavljivanja vuka u budućnosti, a na Zrinskoj i Petrovoj gori se vuk već i ustalio (Jeremić i sur., 2015). Staništa srednje klase prikladnosti potencijalne rasprostranjenosti vuka pokazuju Maceljsko gorje, Kalničko gorje, Ivančica, Strahinjčica te čak i Medvednica. Navedena područja prekrivena su šumom, nalaze se na višim nadmorskim visinama uz povelik broj prijelaza na autocestama pogodnih za korištenje, što sigurno pridonosi budućoj rasprostranjenosti vuka na tim staništima. Ipak uz predviđanje modela treba uzeti u obzir, da su ta područja izolirana od područja poznate rasprostranjenosti vuka, zauzimaju dosta male i izolirane površine šume te prijelazi nemaju niti jedan izgrađeni zeleni most. Sve navedeno otežava prisutnost vuka ondje u skoroj budućnosti.

Utjecaj prometnica, odnosno utjecaj udaljenosti od ceste u negativnoj je korelaciji s mogućnošću pojavljivanja vrste. Najviši postotak vjerojatnosti pojavljivanja uvijek je tamo gdje su prometnice najudaljenije. U slučaju kada se ipak odluče prijeći autocestu, to može završiti njihovom smrću, ali i predstavljati opasnost za sudionike u prometu. Tako je u razdoblju od 2005.-2008. godine, 52 % od ukupno stradalih bilo na prometnicama (Štrbenac i sur., 2010).

Gorski kotar i Lika, uz Velebit i Dalmaciju, posjeduju najveće površine visoko prikladnih staništa. Planinski predjeli zbog dovoljnih visina, šumskih pokrova koji pružaju zaklon vukovima i činjenica da je broj ljudi manji nego u ostalim predjelima, značajke su područja visoke rasprostranjenosti vukova. Područja koja predstavljaju najbolje uvjete staništa za vuka zauzimaju 9 % ukupne površine kopnenog dijela Hrvatske, dok 65 % površine nije prikladno za staništa. Konačni rezultat podudara se s prikupljenim podacima o populaciji vuka za 2010. godinu (Štrbenac i sur., 2010), gdje je najveći broj jedinki procijenjen na području Splitsko-dalmatinske i Ličko-senjske županije.

U konzervaciji vrste važno je razumjeti odnose između prisutnosti vrste i njezinog staništa. Vukovi se smatraju generalistima, što znači da mogu okupirati razne tipove staništa. Njihova sposobnost prilagodbe na širok raspon uvjeta omogućila im je opstanak u fragmentiranim i degradiranim staništima, kao i u onima s velikom gustoćom ljudi. Usprkos tome vukovi mogu pokazivati afinitet prema određenim uvjetima u staništu što sigurno ne bi trebalo zanemariti u procjeni kvalitete staništa (Ciucci i sur., 2003). Dobiveni model može biti koristan alat u procjeni kvalitete staništa na razini Hrvatske.

Modeliranje koridora kretanja napravila sam na području autoceste A6 i A1 iz razloga što one prolaze najvećim dijelom staništa vukova te prolaze kroz najosjetljivija područja. Dobiveni rezultati pokazuju različite opcije potencijalnih koridora koje bi životinja mogla koristiti. Kojim putem će koridor ići, odnosno koji prijelaz će vuk koristiti, ovisi o blizini prvog dostupnog prijelaza i o vrsti staništa kroz koje mora proći. Ukoliko je stanište klasificirano modelom kao neprikladno (bilo to zbog blizine naselja i cesta, nedostupnosti plijena ili drugih razloga) u većini slučajeva vuk će ga zaobići. Koristit će ona područja koja su klasificirana kao visoko i srednje prikladna te prijelaz koji se tada nalazi u blizini. Nadalje, ako prijelaz ipak nije u blizini, njegov put može prijeći i neprikladna područja. Štoviše znaju i ne izbjegavati ceste pogotovo za vrijeme noćnih kretanja, kada ulaze u sela u potrazi za hranom i vodom, pošto je noću najlakše izbjeći susret s ljudima (Kusak i sur., 2005). Ukoliko mu se omoguće potrebni prijelazi prikladne širine za njegovo kretanje, autoceste mu ne moraju predstavljati barijeru. Primjer je vuk Slavc, originalno iz Slovenske populacije koji je napustio Dinarsku populaciju te prošao ukupno 1076 kilometara linearne udaljenosti (Fabbri i sur., 2014). Uspio je prijeći veći broj cesta bez obzira na tip staništa kroz koje se pružao koridor. Primjer Slavca pokazuje kako prikladni prijelazi mogu biti dovoljni, da povežu vučje populacije kroz područja koja su vrlo heterogena i pod velikim ljudskim utjecajem (Ciucci i sur., 2009). Manje populacije nastale zbog fragmentacije staništa imaju znatno veću stopu smrtnosti, stoga su koridori potrebni za povezivanje tih udaljenih fragmenata. Autocesta, dakle, ne predstavlja nepropusnu barijeru, a mnogi postojeći i mogući budući koridori nadalje će samo olakšati neometano kretanje vuka u disperziji ili cijele vučje populacije.

Staništa koja vuk koristi za život, reprodukciju i koja su sastavni dio koridora kretanja su od izuzetne važnosti za populaciju te na njima ne bi smjelo biti nikakve gradnje buduće infrastrukture. Ukoliko se planira gradnja prometnica ili bilo koje druge infrastrukture u bilo kojem od ovih staništa, u njihovom planiranju obvezno bi trebala biti korištena karta pogodnosti staništa. U obzir treba uzeti postojeće prijelaze koje su pogodne za vuka (a tako i za ostale velike zvijeri), ali i one buduće ukoliko su potrebne, preko postojećih autocesta i onih u planiranju. Kod zaštite velikih sisavca očuvanje i obnavljanje neprekidnosti staništa je uvijek jedan od važnijih ciljeva. Želimo li smanjiti negativan utjecaj prometnica potrebno je poznavati teritorij na kojem obitavaju te njihovo ponašanje i aktivnosti. U slučaju vuka, kojem je potrebno veliko područje, konstrukcija prikladnih struktura za prijelaz na pogodnim i ekološki važnim mjestima je izrazito potrebna (Huber i sur., 2002)

## 5. ZAKLJUČCI

1. Ekološke varijable koje su pokazale najveći utjecaj na moguću prisutnost vuka pojedinih područja su nadmorska visina, broj vrsta plijena, udaljenost od cesta, naselja i ruba šume.
2. Na području cijele Hrvatske ima 3482,83km<sup>2</sup> (9%) površina visoko kvalitetnih staništa.
3. Staništa vuka srednje kvalitete na području cijele Hrvatske ima 6964,41 km<sup>2</sup> (12%).
4. Staništa vuka niske kvalitete na području cijele Hrvatske ima 7859,81 km<sup>2</sup> (14%).
5. Područja visoke kvalitete staništa ima najviše na području Like i Velebita sa 1097,95 km<sup>2</sup>.
6. Priloženi model staništa daje detaljniju analizu kvalitete staništa pogodnih za vuka što pridonosi boljem uvidu u ekološke potrebe vuka.
7. Karta potencijalne distribucije može uvelike koristiti u budućim planovima zaštite vuka na području Hrvatske, dati uvid gdje bi se trebala izbjegava gradnja buduće infrastrukture s obzirom na područja trenutne i moguće prisutnosti vuka.
8. Pri budućim planovima gradnje prijelaza za vuka (ali i velikih zvijeri) priloženi koridori mogu biti od koristi, jer pokazuju veliku vjerojatnost kretanja vuka u budućnosti u cilju prelaženja prometnica.



## LITERATURA

- Alegro, A. (2000). Vegetacija Hrvatske (Interna skripta). Botanički zavod PMF-a, Zagreb.
- Anderson, D. R., Burnham, K. P. (2002). Avoiding Pitfalls When Using Information Theoretic Pitfalls Avoiding. *The Journal of Wildlife Management*, 66(3), 912–918.
- Anonimous, 2016. Razlozi ugroženosti. <http://www.life-vuk.hr/vuk/vuk-u-hrvatskoj/razlozi-ugrozenosti-i-smrtnosti/razlozi-ugrozenosti-170.html>
- Anonimous, 2016. Zašto donacije. <http://www.life-vuk.hr/vuk/mjere-zastite-stoke/program-donacije/zasto-donacije-204.html>
- Anonimous, 2016. Procjena brojnosti i trend populacije vuka u Hrvatskoj. <http://www.life-vuk.hr/vuk-u-hrvatskoj/brojnost-i-trend-populacije-vuka-u-hrvatskoj/procjena-brojnosti-i-trenda-populacije-vuka-u-hrvatskoj-163.html>
- Anonimous, 2016. Pristup istraživanju vukova. <http://www.life-vuk.hr/istrazivanje-i-pracenje-vuka/zasto-se-vukovi-istrazuju/pristup-istrazivanju-vukova-173.html>
- Anonimous, 2016. Čopor Risnjak. <http://www.life-vuk.hr/istrazivanje-i-pracenje-vuka/telemetrijski-praceni-copori/copor-risnjak-274.html>
- Anonimous, 2016. Zeleni mostovi. <http://www.life-vuk.hr/prijelazi-za-divlje-zivotinje/prometnice-i-velike-zvijeri/zeleni-mostovi-192.html>
- Arthur, S. M., Schwartz, C. C. (1999). Effects of sample size on accuracy and precision of brown bear home range models. *Ursus*, 11(April 1998), 139–148.
- Boitani, L. (2000). Action plan for the conservation of wolves (*Canis lupus*) in Europe. *Nature and environment*, 113, 1-84.
- Burnham, K. P., Anderson, D. R. (2002). Model selection and multimodel inference: a practical information-theoretic approach. *Ecological Modelling*, 172.
- Chapron, G., Kaczensky, P., Linnell, J. D. C., Arx, M. von, Huber, D., Andrén, H., ... Boitani, L. (2014). Recovery of large carnivores in Europe's modern human-dominated landscapes. *Science*, 346(6216), 1517–1519.
- Ciucci, P., Masi, M., Boitani, L. (2003). Winter habitat and travel route selection by wolves in the northern Apennines, Italy. *Ecography*, 26(2), 223–235.

- Ciucci, P., Reggioni, W., Maiorano, L., Boitani, L. (2009). Long-Distance Dispersal of a Rescued Wolf From the Northern Apennines to the Western Alps. *Journal of Wildlife Management*, 73(8), 1300–1306.
- Clutton- Brock, J., Greensmith A. (2002). What is a mammal? U: Clutton- Brock J. (ur.) *Mammals*. Dorling Kindersley Handbooks, str. 216-231.
- Dormann, C. F., Elith, J., Bacher, S., Buchmann, C., Carl, G., Carré, G., Garcia Marquez, J. R., Gruber, B., Lafourcade, B., Leitao, P. J., Munkemuller, T., McClean, C., Osborne P. E., Reineking, B., Schroder, B., Skidmore, A. K., Zurell D., Lautenbach, S. (2013). Collinearity: A review of methods to deal with it and a simulation study evaluating their performance. *Ecography*, 36(1), 027–046.
- Dupré, E., F. Corsi, L. Boitani (1995). Potential distribution of the wolf in Italy: A multivariate based GIS model. Priopćenje na: Coference on European Wolf Migration 17-2009. Neuchâtel, Switzerland
- Elith, J., Phillips, S. J., Hastie, T., Dudík, M., Chee, Y. E., Yates, C. J. (2011). A statistical explanation of MaxEnt for ecologists. *Diversity and Distributions*, 17(1), 43–57.
- Fabbri, E., Caniglia, R., Kusak, J., Galov, A., Gomerčić, T., Arbanasić, Huber, D., Randi, E. (2014). Genetic structure of expanding wolf (*Canis lupus*) populations in Italy and Croatia, and the early steps of the recolonization of the Eastern Alps. *Mammalian Biology*, 79(2), 138–148.
- Fielding, A. H., Bell, J. F. (1997). A review of methods for the assessment of prediction errors in conservation presence/ absence models. *Environmental Conservation*, 24(1), 38–49.
- Franklin, J. (2010). Mapping species distributions. Spatial inference and prediction. *Ecology, Biodiversity and Conservation*, 53(9), 340.
- Gomerčić, T., Sindičić, M., Galov, A., Arbanasić, H., Kusak, J., Kocijan, I., Đuras-Gomerčić, M., Huber, D. (2010). High Genetic Variability of the Grey Wolf (*Canis lupus* L.) Population from Croatia as Revealed by Mitochondrial DNA Control Region Sequences. *Zoological Studies* 49(6): 816-823 (2010)

Gužvica, G., Gomerčić, T., Šver, L., Huber, Đ. (2005). Praćenje kretanja divljih životinja korištenjem foto zamki.

<http://www.drypis.info/Teku%C4%87egodi%C5%A1te/Pra%C4%87enjekretanjadivljih%C5%BEivotinja/tabid/156/Default.aspx>

Halavuk, T. (2013) Zoogeografska analiza rasprostranjenosti gujavica (Lumbricidae) na području Hrvatske. Diplomski rad. Osijek : Sveučilište Josipa Jurja Strossmayera u Osijeku

Hanzak, J. (1974). Beasts of prey. U: Mammals of Britain and Europe. Hamlyn. London, str. 41-45.

Huber, Đ., Kusak, J. (n.d.). (2000). Autocesta Bregana - Zagreb - Dubrovnik : studija utjecaja na velike zvijeri : Dionica : Bosiljevo - Sveti Rok.

Huber, Đ. (2001). Utjecaj prometa na divlje životinje u hrvatskoj. U: Jelčić I. (ur.) Ekologija i medicina u prometu. Zagreb : HAZU, str. 28-38

Huber, Đ, Tvrtković, N, Dušek, A, Štahan, Ž, Pavlinić, I, Krivak Obadić, V, Budak Rajčić, D. (2002c). Propusnost cesta za životinje (Prijedlog smjernica za projektiranje).- Institut građevinarstva Hrvatske, 1-67

Huber, Đ., Kusak, J., Štrbenac, A. (2010). Poželjni i mogući kapacitet. U: A. Štrbenac (Ur.), Plan upravljanja vukom u Republici Hrvatskoj (p. 128). Zagreb: Državni zavod za zaštitu prirode.

Janicki Z., Slavica A., Konjević D., Severin K. (2007). Zoologija divljači. Zavod za biologiju, patologiju i uzgoj divljači. Sveučilište u Zagrebu Veterinarski fakultet, Zagreb.

Jelaska, S. D. (1997). Primjena geografskih informacijskih sustava u botanici. Zbornik sažetaka priopćenja, Šesti kongres biologa Hrvatske

Jeremić, J., Štrbenac, A., Oković, P., Katušić, L., Kusak, J., Leko, K. (2011). Velike zvijeri u Hrvatskoj. Državni zavod za zaštitu prirode, Zagreb.

Jeremić, J., Štrbenac, A., Kusak, J., Huber, Đ. (2015). Izvješće o stanju populacije vuka u Hrvatskoj u 2015 . godini, Hrvatska agencija za okoliš i prirodu, Zagreb.

- Kaczensky, P., Chapron, G., von Arx, M., Huber, D., Andrén, H., and Linnell, J. (2013). Status, management and distribution of large carnivores - bear, lynx, wolf & wolverine - in Europe. Part 1 - Europe summaries. Report: 1-72. A Large Carnivore Initiative for Europe Report prepared for the European Commission
- Krpan, H. (2013). Korelacije. <http://www.znanostblog.com/korelacije/>
- Kusak, J., Huber, D., Frković, A. (2000). The effects of traffic on large carnivore populations in Croatia. *Biosphere Conservation*, 3(1), 35–39.
- Kusak, J., 2004. Sivi vuk (*Canis lupus* L.). U: Mustapić, Z., Frković, A., Lekić, M., Lovrić, I. (Ur.) *Lovstvo*. Zagreb, Hrvatski lovački savez, str. 597, 130-135.
- Kusak, J., Singer, D., & Desnica, S. (2005). Vjerojatnost pojavljivanja vuka u Hrvatskoj. Zagreb: LIFE III VUK projekt, GIS karta, DZZP
- Kusak, J., Skrbinšek, A. M., Huber, D. (2005). Home ranges, movements, and activity of wolves (*Canis lupus*) in the Dalmatian part of Dinarids, Croatia. *European Journal of Wildlife Research*, 51(4), 254–262.
- Kusak, J., Huber, D., Gomerčić, T., Schwaderer, G., Gužvica, G. (2009). The permeability of highway in Gorski kotar (Croatia) for large mammals. *European Journal of Wildlife Research*, 55(1), 7–21.
- Kusak, J. (2010). Kretanje vukova i struktura čopora. U: A. Štrbenac (Ur.), *Plan upravljanja vukom u Republici Hrvatskoj* (pp. 21–26). Zagreb: DZZP
- Kusak, J., Huber, D., Trenc, N., Desnica, S., & Jeremić, J. (2016). Stručni priručnik za procjenu utjecaja zahvata na velike zvijeri pojedinačno te u sklopu planskih dokumenata Verzija 1.0 - primjer vjetroelektrane. Zagreb: Agencija za zaštitu okoliša
- Lobo, J. M., Jiménez-valverde, A., Real, R. (2008). AUC: A misleading measure of the performance of predictive distribution models. *Global Ecology and Biogeography*, 17(2), 145–151.
- Mech L. D., Boitani L. (2003). *Wolf Social Ecology*. U: Mech L. D., Boitani L. (ur.) *Wolves: behaviour, ecology, and conservation*. University of Chicago Press, Chicago, str. 1-34.

- Pahernik, M. (2006). Uvod u Geografsko Informacijske Sustave. Ministarstvo obrane Republike Hrvatske, Glavni stožer Oružanih snaga RH, Zapovjedništvo za združenu izobrazbu i obuku "Petar Zrinski", Zagreb
- Phillips, S. J., Anderson, R. P., Schapire, R. E. (2006). Maximum entropy modeling of species geographic distributions .Ecological Modelling, 190(3–4), 231–259.
- Phillips, S. J., Dudík, M., Elith, J., Graham H., C., Lehman, A., Leathwick, J., Ferrier, S. (2009). Sample selection bias and presence-only distribution models : implications for background and pseudo-absence data Reference Sample selection bias and presence-only distribution models : implications for background and pseudo-absence data, 19(1), 181–197.
- Platiša, M., Pintar, I., & Kusak, J. (2011). Tjelesne osobine sivog vuka (*Canis lupus* L.). Veterinar, 49(1), 16–27.
- Radosavljevic, A., Anderson, R. P. (2014). Making better Maxent models of species distributions: Complexity, overfitting and evaluation. Journal of Biogeography, 41(4), 629–643.
- Radović, J., Čivić, K., Topić, R., Posavec Vukelić, V. (2009). Biodiversity of Croatia. State Institute for Nature Protection, Ministry of Culture - Republic of Croatia, Zagreb.
- Shcheglovitova, M., Anderson, R. P. (2013). Estimating optimal complexity for ecological niche models: A jackknife approach for species with small sample sizes. Ecological Modelling, 269, 9–17.
- Slijepčević, V. (2009) Telemetrijsko istraživanje euroazijskih risova (*Lynx lynx*) u Hrvatskoj. Diplomski rad. Zagreb : Veterinarski fakultet.
- Syfert, M. M., Smith, M. J., Coomes, D. A. (2013). The Effects of Sampling Bias and Model Complexity on the Predictive Performance of MaxEnt Species Distribution Models. PLoS ONE, 8(2).
- Štrbenac, A., Huber, Đ., Kusak, J., Majić Skrbinišek, A., Frković, A., Štahan, Ž., ... Štrbenac, P. (2005). Wolf management plan for Croatia. (A. Štrbenac, Ed.). Zagreb: Državni zavod za zaštitu prirode.

Štrbenac, A., Huber, Đ., Kusak, J., Oković, P., Sindičić, M., Jeremić, J., Frković, A., Gomerčić, T. (2008). Očuvanje velikih zvijeri u Hrvatskoj. Državni zavod za zaštitu prirode, Zagreb.

Štrbenac, A., Kusak, J., Huber, Đ., Jeremić, J., Oković, P., Majić-Skrbinšek, A., Vukšić, I., Katušić, L., Desnica, S., Gomerčić, T., Bišćan, A., Zec, D., Grubešić, M. (2010). Plan upravljanja vukom u Republici Hrvatskoj za razdoblje 2010 - 2015. Državni zavod za zaštitu prirode, Zagreb.

Vivoda, B., Huber, Đ., Reljić, S., Kusak, J. (2014). Divlje životinje i promet na autocestama. Glasilo hrvatskog društva za ceste - via vita , Zagreb.

Warren, D. L., Seifert, S. (2011). Ecological niche modeling in Maxent: the importance of model complexity and the performance of model selection criteria. *Ecological Society of America*, 21(2), 335–342.

Yost, A. C., Petersen, S. L., Gregg, M., Miller, R. (2008). Predictive modeling and mapping sage grouse (*Centrocercus urophasianus*) nesting habitat using Maximum Entropy and a long-term dataset from Southern Oregon. *Ecological Informatics*, 3(6), 375–386.

Zlatanova, D., Dutsov, A., Valchev, K., Huber, Đ., Kusak, J., Schwaderer, G., ... Spangenberg, A. (2010). Recommendations for the reduction of habitat fragmentation caused by transport infrastructure development. Radolfzell, Germany: EuroNatur Foundation.

Izvor slika:

[http://www.dzpz.hr/slike\\_upload/20100303/dzpz201003031313290](http://www.dzpz.hr/slike_upload/20100303/dzpz201003031313290)

<http://img.photobucket.com/albums/v603/sefica/vuk.jpg>

<http://otvoreno.ba/wp-content/uploads/2015/12/vukovi.jpg>

<http://www.life-vuk.hr/mjere-zastite-stoke/elektricne-ograde/sto-je-elektricna-ograde-198.html>

<https://www.arz.hr/hr/autocesta/dionice/delnice-ravna-gora>

<http://www.drypis.info/2006/ZelenimostOsmakovac/tabid/196/Default.aspx>

[http://www.gin.hr/hr/projekti/infrastruktura/tunel-brinje-\(autocesta-zagreb---split\),51.html](http://www.gin.hr/hr/projekti/infrastruktura/tunel-brinje-(autocesta-zagreb---split),51.html)

# ŽIVOTOPIS

## OSOBNJE INFORMACIJE



Vukelić Matea  
Braće Domany 2, 10000 Zagreb (Hrvatska)



++385 / 91 539 8239



matea.vukelic31@gmail.com

Spol Žensko | Datum rođenja 31. siječnja 1993. | Državljanstvo hrvatsko

## RADNO ISKUSTVO

Ožujak 2013- Travanj 2013

### Terenski geolog

- sakupljanje, pranje, ispitivanje i prepoznavanje uzoraka minerala i stijena
- izrada geološkog profila i geološkog stupa
- determinacija magmatskih, sedimentnih i metamorfnih stijena
- utvrđivanje osnovnih strukturnih i tektonskih karakteristika stijena
- analiza mineralnog sastava i strukture
- pisanje dnevnih izvješća te slanje na pregled profesorima

Ožujak 2013- Travanj 2013, Svibanj 2014- Lipanj 2014, Lipanj 2015- Srpanj 2015

### Terenski biolog

- sakupljanje biljnog materijala, utvrđivanje vrsta, izrada herbarija vaskularne flore
- prikupljanje uzoraka i determinacija vodenih i kopnenih beskralješnjaka
- primjena metoda mjerenja fizičko-kemijskih karakteristika voda stajaćica i tekućica
- značajke zajednica plankton, perifitona i bentosa
- procjenu saprobnosti vode na temelju kvalitativnog i kvantitativnog sastava biote
- promatranje ribljih zajednica kao pokazatelja kvalitete vode
- monitoring jezera s različitim stupnjevima trofije te razrađivanje mogućnosti usporavanja eutrofikacije
- promatranje raznolikosti invertebrate na različitim podlogama
- primjena metode uzorkovanja na malim sisavcima i monitoring šišmiša
- primjena ključa za determinaciju sisavaca
- priprema mikroskopskih uzoraka

10. Travanj, 2015

### Sudjelovanje na projektu fakulteta "Noć biologije"

- rad sa grupom studenata u cilju razvoja modela za predstavljanje utjecaja odlagališta na okoliš
- 11-13. Ožujak, 2015

Sudjelovanje u međunarodnoj radionici " Biodiversity in the mediterranean basin in Koper"

Svibanj 2014 - Lipanj 2014

#### Terenski geograf

- uvod u elemente i korištenje topografskih karata
- određivanje koordinata, korištenje kompasa i GPS uređaja,
- kretanje zadanim rutama, orijentacija na terenu
- utvrđivanje geomorfoloških procesa i oblika na terenu
- prepoznavanje morfo-genetskih karakteristika reljefa
- mapiranje geomorfolškog sadržaja na topografske karte

## OBRAZOVANJE I OSPOSOBLJAVANJE

Rujan 2012- Srpanj 2014 Sveučilišni prvostupnik struke znanosti o okolišu

Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Zagreb, Hrvatska

- **Bitni kolegiji** – onečišćenje atmosfere I globalno zagrijavanje, kartografske osnove GIS-a, botanika, klimatologija, terenska nastava iz biološke, geografske I geološke zaštite, geologija zaštite okoliša, invertebrata, gospodarenja morem i zaštita ,vertebrata, genetika, animalna fiziologija

Rujan 2014 - Siječanj 2016 **Pisanje diplomskog rada**

Završavanje diplomskog rada na temu " Modeliranje koridora kretanja vukova (Canis lupus Linnaeus, 1758) u Hrvatskoj

## OSOBNJE VJEŠTINE

Materinski jezik

Hrvatski

Ostali jezici

engleski

njemački

RAZUMIJEVANJE		GOVOR		PISANJE
Slušanje	Čitanje	Govorna interakcija	Govorna produkcija	
C1	C1	C1	B2	B2
A1	A1	A1	A1	A1

Stupnjevi: A1 i A2: Početnik - B1 i B2: Samostalni korisnik - C1 i C2: Iskusni korisnik  
[Zajednički europski referentni okvir za jezike](#)

Komunikacijske vještine

Izvršne komunikacijske vještine i sposobnost prilagode multikulturalnom okruženju, dobiveno sudjelovanjem u nekoliko projekata i radu s ljudima iz različitih osobnih i profesionalnih pozadina. Vrlo dobro razumijevanje timskog rada stekla sudjelujući u raznim timski organiziranim zadacima tijekom studija.

Organizacijske / rukovoditeljske  
vještine

- tijekom studija organizirala prezentacije o zagađenju okoliša
- surađivala sa grupom studenata na godišnjem sveučilišnom projektu "Noć biologije"



Ostale vještine

Sudjelovanje na turnirima u preponskom jahanju, plesanje baleta

Digitalna kompetencija

SAMOPROCJENA				
Obrada informacija	Komunikacija	Stvaranje sadržaja	Sigurnost	Rješavanje problema
Samostalni korisnik	Iskusni korisnik	Samostalni korisnik	Temeljni korisnik	Samostalni korisnik

[Informacijsko-komunikacijske tehnologije - tablica za samoprocjenu](#)

- Iskusna sa Microsoft Office aplikacijama, Windows
  - Iskusna sa ArcGIS, Maxent, ENMTools

Vozačka dozvola

B